

SVEUČILIŠTE U SPLITU

EKONOMSKI FAKULTET U SPLITU

DIPLOMSKI RAD

EVALUACIJA PERFORMANSI
KOMERCIJALNIH BANAKA U REPUBLICI
HRVATSKOJ VIŠEKRITERIJSKIM
MODELIMA

Mentor: **prof.dr.sc. Zoran Babić**

Student: **Ivandić Jure**

Broj indeksa: **2172453**

Split, lipanj, 2019.

SADRŽAJ:

1. UVOD	1
1.1. Problem istraživanja	1
1.2. Predmet istraživanja	3
1.3. Ciljevi istraživanja	5
1.4. Metode istraživanja	5
1.5. Doprinos istraživanja	6
2. KRATAK PRIKAZ MODELA I METODA POGODNIH ZA EVALUACIJU PERFORMANSI BANAKA.....	7
2.1. CAMELS rejting	7
2.2. Analiza omeđivanjem podataka (AOP)	8
2.3. Prethodna istraživanja o evaluaciji performansi banaka	9
3. METODE ZA VIŠEKRITERIJALNO ODLUČIVANJE I POSTAVKA PROBLEMA.....	12
3.1. Višekriterijalno odlučivanje	12
3.2. Pojam i karakteristike metoda za procenjivanje težine kriterija	13
3.2.1. Metoda svojstvenog vektora	13
3.3. Analitički hijerarhijski proces (AHP)	17
3.4. TOPSIS metoda	18
3.5. PROMETHEE metoda	21
3.6. Definiranje glavnih kriterija i potkriterija	28
3.6.1 Razvoj modela za uspoređivanje i rangiranje banaka	31
4. IMPLEMENTACIJA MODELA.....	36
4.1. Procjena težina kriterija	36
4.2. Komparacija banaka PROMETHEE metodom	42
4.3. Komparacija banaka TOPSIS metodom	49
4.4. Usporedba rezultata dobivenih PROMETHEE metodom i TOPSIS metodom.....	56
5. ZAKLJUČAK.....	58
SAŽETAK.....	59
SUMMARY.....	59
LITERATURA.....	60
POPIS SLIKA I TABLICA.....	63

1. UVOD

1.1. Problem istraživanja

Postoje različiti motivi i interesi za mjerenje i procjenu performansi banaka. Pravodobno prepoznavanje problema u poslovanju finansijskih institucija vrlo je važno jer problemi koji mogu proizaći zbog lošeg upravljanja pojedinim bankama mogu ugroziti i cijeli finansijski sustav zemlje, stoga su potrebne metode kojima bi se na vrijeme mogli poduzeti koraci za zaštitu interesa građana. U svom radu Hunjak i Jakovčević (2003) navode da je sa stajališta interesa vlasnika pojedine banke, za njezino efikasno poslovanje, važno znati usporediti se s konkurentskim bankama i identificirati uzroke svoje (ne)efikasnosti, a sa stajališta pojedinca je procjena performansi banke važna zbog potrebe da se zaštiti od rizika poslovanja s rizičnom bankom ili zbog špekulativnih motiva povezanih s aktivnostima na tržištu kapitala. Iskustva s ocjenjivanjem performansi hrvatskih banaka i njihovim rangiranjem nisu velika. Tradicionalno se svake godine u stručnoj literaturi rangiraju banke po veličini aktive, a složeniji modeli, koji bi omogućili njihovu višekriterijsku evaluaciju, povremeno se objavljuju kao rezultat istraživanja stručnjaka uglavnom izvan finansijskih institucija. Mjerenje performansi banaka tradicionalno se temelji na analizi finansijskih pokazatelja (finansijskih omjera). Međutim, analizu finansijskih omjera treba nadopuniti i različitim kvalitativnim karakteristikama poput kvalitete menadžmenta, strukture vlasništva, konkurentne pozicije i drugih da bi se u potpunosti zadovoljila potreba za analizom i vrednovanjem efikasnosti poslovanja. Tradicionalno rangiranje uspješnosti banaka temelji se na jednostavnim i dosljednim čimbenicima kao što su finansijski prinosi, povrat na imovinu (ROA) i povrat na zaradu (ROE). Hannay i Sutter (1997) su pokazali da rangiranje performansi provedeno na ovaj način ne može točno ilustrirati institucije koje prihvaćaju strategije za održavanje vrhunske učinkovitosti. Abdelgawad i Fayek (2010) su identificirali kritične čimbenike uspjeha u poslovanju banaka i grupirali ih u osam glavnih kategorija: 1) profitabilnost, 2) učinkovitost i produktivnost, 3) upravljanje ljudskim resursima, 4) upravljanje rizikom, 5) učinkovitost prodaje, 6) kvaliteta usluge, 7) upravljanje kapitalom i 8) konkurentno pozicioniranje. Finansijske i nefinansijske mjere spajaju se zajedno u uravnoteženi sustav koji uzima u obzir različita područja bankarske aktivnosti. Može se predložiti da takav pristup pomaže ocjenjivanju uspješnosti banaka na sveobuhvatan način. U većini zemalja poslovna banka je jedna od najvažnijih finansijskih institucija. Može privući finansijske tokove, ponuditi kreditne usluge i razne finansijske usluge. „Ove aktivnosti imaju

presudan utjecaj na nacionalni gospodarski razvoj. Stoga bi komercijalne banke trebale biti ocijenjene i analizirane modernim i preciznim tehnikama za rangiranje komercijalnih banaka u bankarskom sustavu i poboljšanje njihovih performansi“ (Cuong et. al., 2017).

PROMETHEE i AHP (analitički hijerarhijski proces) modeli su odabrani na temelju nekoliko razloga. „Prvo, omogućuju razmatranje financijskih i nefinancijskih mjera u procesu evaluacije, što je vrlo važno zbog toga jer poslovanje banaka je vrlo složeno i stoga nije dovoljno uzeti u obzir samo financijske mjere. Pomažu u otkrivanju rangiranja banaka i prepoznavanju boljeg učinka banaka i onih kojima je potrebna veća pozornost ili od nadzornih institucija ili uprave kako bi se poboljšala trenutna učinkovitost“ (Stankevičienė i Menacite, 2012). Ovaj model također uključuje vanjsko prosuđivanje koje bi moglo pomoći u izgradnji specifičnijeg okvira vrednovanja.

Primjena višekriterijskih modela u poslovanju banaka bila je istraživački interes nakon kraja 1990-ih, a većina značajnih primjena pronađena je nakon 2000. Za procjenu uspješnosti banaka Jabalameli i Rasoulinezhad (2011) su koristili (DEA-Data Envelopment Analysis i AHP), a Lu et.al., (2013) u svojoj studiji su se koristili (AHP-om) za procjenu ocjene rizika poslovanja banke u različitim scenarijima i određivanju prioritetnih stavki ocjenjivanja. Čehulić et.al., (2011) koristili su financijske pokazatelje podijeljene u četiri skupine kao što su omjeri bilance, omjeri računa dobiti i gubitka, pokazatelji profitabilnosti i tržišni pokazatelji te nekoliko podskupina za analizu banaka u Hrvatskoj AHP-om.

1.2. Predmet istraživanja

Predmet istraživanja rada temeljen je na problemu istraživanja, a to je evaluacija performansi te usporedba i rangiranje hrvatskih banaka. Ovaj rad istražuje determinante performansi izražene financijskim omjerima i određuje financijske rezultate komercijalnih banaka u Republici Hrvatskoj pomoću PROMETHEE i TOPSIS metoda i AHP-a. Metode PROMETHEE i TOPSIS se koristi za konačnu ocjenu hrvatskih banaka, a AHP kako bi se utvrdila važnost kriterija na temelju njihovih financijskih i nefinancijskih obilježja. Banke su u radu rangirane na temelju kvantitativnih i kvalitativnih kriterija prema podacima o njihovom poslovanju od 2014. do 2016. godine. Kvantitativni i financijski parametri izvedeni su razdvajanjem četiri glavna kriterija: likvidnosti, efikasnosti, profitabilnosti i adekvatnosti kapitala, a kvalitativni kriteriji odabrani su u skladu s obilježjima koja se koriste u postojećim sustavima za evaluaciju i nadzor banaka. Odabrani omjeri pokrivaju sve aspekte financijskog poslovanja poduzeća, uključujući profitabilnost, solventnost i likvidnost. Model se temelji na višekriterijalnom pristupu, objedinjuje financijske i nefinancijske mjere vrednovanja i sastoji se od primjene višekriterijalne tehnike donošenja odluka kao što su PROMETHEE i TOPSIS. Upotreba modela i empirijski test omogućili su međusobnu usporedbu i rangiranje banaka koje zauzimaju vodeće pozicije na tržištu. Model pomaže ocjenjivanju banaka i njihovom učinku kombinirajući različite prednosti višekriterijskog odlučivanja s jednim uravnoteženim sustavom. Usporedbom i komentiranjem rezultata navedenih metoda dobiva se uvid u razlike kod konačnih odabira. Implementacija modela demonstrirat će se na skupu od 26 komercijalnih banaka koje su na hrvatskom tržištu poslovale i bile aktivne u razdoblju od 2014. do 2016. godine.

TABLICA 1.1. Vlasnička struktura banaka i udio njihove imovine u imovini svih banaka, na kraju razdoblja						
	XII. 2014.		XII. 2015.		XII. 2016.	
	Broj banaka	Udio	Broj banaka	Udio	Broj banaka	Udio
Domaće vlasništvo	12	9,9	12	9,7	11	10,3
Domaće privatno vlasništvo	10	4,7	10	4,4	8	4,0
Domaće državno vlasništvo	2	5,2	2	5,3	3	6,3
Strano vlasništvo	16	90,1	16	90,3	15	89,7
Ukupno	28	100,0	28	100,0	26	100,0

Izvor: HNB

Tablica 1.1. prikazuje vlasničku strukturu banaka koje su poslovale i bile aktivne u Republici Hrvatskoj tijekom razdoblja od 2014. do 2016. godine. U 2016. godini broj banaka smanjio se

za dva, stoga je za potrebe ovog rada uzeto u obzir 26 komercijalnih banaka koje su poslovale tijekom cijelog razdoblja od 2014. do 2016. godine.

U nastavku su navedene banke koje su izabrane za analizu u ovom radu.

Tablica 1.2. Kreditne institucije i sjedišta

Red. br. na dan 31. XII. 2016.	Naziv kreditne institucije i sjedište
1.	Addiko Bank d.d., Zagreb ¹⁾
	Banco Popolare Croatia d.d., Zagreb ²⁾
2.	Banka Kovanica d.d., Varaždin
	Banka splitsko-dalmatinska d.d., Split ³⁾
	BKS Bank d.d., Rijeka ⁴⁾
	Centar banka d.d., Zagreb ⁵⁾
	Credo banka d.d., Split ⁶⁾
3.	Croatia banka d.d., Zagreb
4.	Erste&Steiermärkische Bank d.d., Rijeka
5.	Hrvatska poštanska banka d.d., Zagreb
6.	Imex banka d.d., Split
7.	Istarska kreditna banka Umag d.d., Umag
8.	Jadranska banka d.d., Šibenik ⁷⁾
9.	Karlovačka banka d.d., Karlovac
10.	KentBank d.d., Zagreb ⁸⁾
11.	Kreditna banka Zagreb d.d., Zagreb
	Međimurska banka d.d., Čakovec ⁹⁾
	Nava banka d.d., Zagreb ¹⁰⁾
12.	OTP banka Hrvatska d.d., Zadar
13.	Partner banka d.d., Zagreb
14.	Podravska banka d.d., Koprivnica
15.	Primorska banka d.d., Rijeka
16.	Privredna banka Zagreb d.d., Zagreb
17.	Raiffeisenbank Austria d.d., Zagreb
18.	Samoborska banka d.d., Samobor
19.	Sberbank d.d., Zagreb ¹¹⁾
20.	Slatinska banka d.d., Slatina
21.	Société Générale-Splitska banka d.d., Split ¹²⁾
22.	Štedbanka d.d., Zagreb
23.	Tesla štedna banka d.d., Zagreb ¹³⁾
24.	Vaba d.d. banka Varaždin, Varaždin ¹⁴⁾
25.	Veneto banka d.d., Zagreb
26.	Zagrebačka banka d.d., Zagreb

Izvor: HNB

1) Hypo Alpe-Adria-Bank d.d., Zagreb, promijenila je 11. srpnja 2016. ime u Addiko Bank d.d., Zagreb.

2) Banco Popolare Croatia d.d., Zagreb, pripojena je 1. prosinca 2014. OTP banci Hrvatska d.d., Zadar.

- 3) Dana 1. srpnja 2016. otvoren je stečajni postupak nad Bankom splitsko-dalmatinskom d.d., Split.
- 4) BKS Bank d.d., Rijeka, pripojena je 1. listopada 2016. BKS Bank AG, Klagenfurt. Istodobno, s radom je započela BKS Bank AG, Glavna podružnica Rijeka, koja je 30. lipnja 2017. promijenila ime u BKS Bank AG, Glavna podružnica Hrvatska.
- 5) Dana 30. rujna 2013. otvoren je stečajni postupak nad Centar bankom d.d., Zagreb.
- 6) Credo banci d.d., Split, 22. studenoga 2011. oduzeto je odobrenje za rad i donesena je odluka o pokretanju postupka prisilne likvidacije. Dana 16. siječnja 2012. otvoren je stečajni postupak.
- 7) Dana 9. listopada 2015. nad Jadranskom bankom d.d., Šibenik, otvoren je postupak sanacije.
- 8) Banka Brod d.d., Slavonski Brod, promijenila je 6. srpnja 2012. ime u KentBank d.d., Zagreb.
- 9) Međimurska banka d.d., Čakovec, pripojena je 1. prosinca 2012. Privrednoj banci Zagreb d.d., Zagreb.
- 10) Dana 1. prosinca 2014. otvoren je stečajni postupak nad Nava bankom d.d., Zagreb.
- 11) Volksbank d.d., Zagreb, promijenila je 18. siječnja 2013. ime u Sberbank d.d., Zagreb.
- 12) Société Générale-Splitska banka d.d., Split, promijenila je 15. svibnja 2017. ime u Splitska banka d.d., Split.
- 13) Štedna banka malog poduzetništva d.d., Zagreb, promijenila je 23. svibnja 2011. ime u Tesla štedna banka d.d., Zagreb.
- 14) Vaba d.d. banka Varaždin, Varaždin, promijenila je 2. siječnja 2017. ime u J&T banka d.d., Varaždin.

1.4. Ciljevi istraživanja

Cilj ovog rada je istaknuti da problemi financijskih odluka imaju snažan višekriterijski karakter te da se utvrde prioritete za parametre poslovanja komercijalnih banaka među identificiranim financijskim pokazateljima i rangiraju banke prema tim pokazateljima.

Razvoj i korištenje novog pristupa ovom problemu tj. analizi problema procjene performansi banaka kao problema višekriterijskog odlučivanja budući da je potrebno uključiti više elemenata u procjenu istodobno.

1.5. Metode istraživanja

Metode koje će se koristiti u diplomskom radu su znanstvene i istraživačke metode.

U radu će se koristiti sljedeće znanstvene metode:

- Metoda sinteze: metoda koja se koristi da bi se činjenični jednostavniji dijelovi povezali u smislene cjeline i da bi se na taj način doprinijelo stvaranju zaključaka iz naočigled različitih, ali vrlo usko povezanih kategorija.
- Metoda indukcije: se koristi za izvođenje općih zaključaka iz pojedinačnih činjenica.
- Metoda dedukcije: polazi od općih zaključaka iz kojih se izvode pojedinačne nove činjenice.
- Metoda deskripcije: koristi se za opisivanje problema i događaja u diplomskom radu.

- Metoda analize: koristi se za razlaganje i rastavljanje kompleksne cjeline na složene dijelove te za simultano objašnjenje čitatelju sa svrhom ispitivanja točnosti postavljenih hipoteza.
- Metoda kompilacije: postupak preuzimanja tuđih rezultata znanstvenog i istraživačkog rada, odnosno tuđih opažanja, stavova, zaključaka i spoznaja uz u što većoj mjeri osobni pristup pisanju te citiranju onoga što je preuzeto od drugih.
- Metoda dokazivanja: utvrđivanje istinitosti pojedinih hipoteza, a koristi se uz metodu analize.¹

Zbog podjele rada na empirijski i teorijski dio, bit će potrebno prikupiti kvalitativne i kvantitativne podatke. Obrazloženje dobivenih rezultata temelji se na analizi sekundarnih izvora podataka (znanstveni i stručni radovi, dokumentacija i zakonski propisi iz domene bankarstva). Kod izrade empirijskog dijela rada podaci će se prikupljati iz već postojećih izvora.

Srednje financijske vrijednosti izračunate su iz godišnjih izvješća 26 komercijalnih banaka odabranih za analizu u ovoj studiji. Procijenjeni su prosječni trogodišnji omjeri od 2014. do 2016. godine, a odabir glavnih kriterija i podkriterija je utemeljen na ključnim pokazateljima uspješnosti Hrvatske Narodne Banke i pregledima financijske literature. U radu će se prikazati primjena AHP metode, TOPSIS i PROMETHEE metoda u cilju uspoređivanja banaka po različitim kriterijima.

1.6. Doprinos istraživanja

Ovim radom nastoji se osim teorijskog pregleda literature o metodama poslovnog odlučivanja, na temelju njihove primjene na temu višekriterijalnog odlučivanja rangirati komercijalne banke u Republici Hrvatskoj po unaprijed odabranim kriterijima. Primjena AHP-a te PROMETHEE i TOPSIS metoda, omogućit će ocjenu performanse komercijalnih banaka te njihovu komparaciju na temelju određenih kriterija. Doprinos u razvoju i korištenju okvira za procjenu poslovnih banaka u Republici Hrvatskoj na temelju metoda višekriterijalnog odlučivanja.

¹ Dostupno na: http://www.pravnifakultetsplit.unist.hr/uploads/MZIR-Prilog_Predavanju4.pdf (10.03.2019.)

2. KRATAK PRIKAZ MODELA I METODA POGODNIH ZA EVALUACIJU PERFORMANSI BANAKA

2.1. CAMELS rejting (Investopedia, 2018)

CAMELS je priznati međunarodni sustav ocjenjivanja koji nadzorna tijela banaka koriste kako bi ocijenila financijske institucije prema šest čimbenika koje predstavlja akronim CAMELS (Capital, Asset, Management, Equity, Liquidity, Sensitivity). Sustav je razvijen u SAD-u sedamdesetih godina sa svrhom da se što ranije identificiraju problemi u poslovanju pojedinih banaka i da se na vrijeme poduzmu korektivne akcije koje su u državnoj ovlasti. Ovaj sustav razvio je vladin ured Federal Deposit Insurance Corporation (FDIC). Osjetljivost na "tržišni rizik", "S" u CAMELS-u je složeno i razvijajuće područje mjerenja. Federalne rezerve i Ured kontrolora valute (eng. Office of the Comptroller of the Currency-OCC) dodali su ga 1995. godine prvenstveno radi rješavanja kamatnog rizika, osjetljivosti svih kredita i depozita na relativno iznenadne i neočekivane promjene kamatnih stopa (Wirnkar i Tanko, 2008).

Sustav se razvija tako da se rejting pojedine banke određuje na temelju vrednovanja šest komponenata koje odražavaju njezine performanse: adekvatnosti kapitala, kvaliteta imovine, menadžmenta, vlasničkog kapitala, likvidnosti i osjetljivosti. Ispitivači procjenjuju adekvatnost kapitala institucija analizom trenda kapitala. Kvaliteta imovine označava procjenu kreditnog rizika povezanog s određenom imovinom, a u CAMELS sustavu pokriva kvalitetu institucionalnih zajmova, što odražava zaradu institucije. Procjena menadžmenta određuje je li institucija sposobna pravilno reagirati na financijski stres. Sposobnost institucije da stvori odgovarajuće prinose kako bi se mogla proširiti, zadržati konkurentnost i dodati kapital ključan je čimbenik u ocjenjivanju njegove održivosti. U procjeni likvidnosti tvrtke ispitivači razmatraju osjetljivost rizika kamatnih stopa, dostupnost sredstava koja se lako mogu pretvoriti u gotovinu, ovisnost o kratkoročnim promjenjivim financijskim resursima i tehničku kompetenciju upravljanja aktivom i pasivom. Osjetljivost pokriva kako pojedine izloženosti riziku mogu utjecati na institucije.

Sustav pomaže regulatorima identificirati banke koje su u problemima. U CAMELS modelu nadzorna tijela svakoj banci dodjeljuju bodove na skali. Ocjena jedan smatra se najboljom, a ocjena pet smatra se najlošijom za svaki faktor. Ovi pojedinačni rangovi zatim se sintetiziraju u jedinstven rang. Direktnu korist od ovoga sustava za nadzor poslovanja banaka javnost nema, naime CAMELS rejting pojedine banke je povjerljiva informacija koja je poznata samo

ocjenjivaču i menadžmentu banke te služi isključivo za nadzor banaka. Na temelju postignutog rejtinga određuje se frekvencija revizije poslovanja banaka; banke s CAMEL rejtingom 1 i 2 predstavljaju najmanje zabrinutosti za regulatore, banke s ocjenom 3 predstavljaju određeni stupanj zabrinutosti, a banke s rejtingom 4 i 5 su problematične banke te predstavljaju srednju do povišenu razinu nadzora i zahtijevaju određene promjene. Bankovni menadžeri moraju pomno promatrati svoj institucionalni CAMELS rejting da bi osigurali da njihova razina rizika nije visoka i ako jeste da poduzmu akcije.

2.2. Analiza omeđivanjem podataka (AOP)

AOP (eng. Data Envelopment Analysis-DEA) predstavlja metodu neparametarskoga linearnog programiranja koja se koristi za procjenu i mjerenje efikasnosti jedinica za odlučivanje (eng. Decision making units-DMU) poput banaka, poslovnica banaka, škola, bolnica i sličnih institucija koje imaju iste ulaze i izlaze, a međusobno se razlikuju prema razini resursa kojima raspolažu i razini aktivnosti unutar procesa transformacije (Šporčić et.al., 2010.)

Najvažnija prednost AOP-a u odnosu na tradicionalne ekonometrijske granične studije jest da je to neparametrijska, deterministička metoda i stoga ne zahtijeva a priori pretpostavke o analitičkom obliku proizvodne funkcije. Stoga je vjerojatnost pogrešne specifikacije proizvodne tehnologije nula. Nedostatak je što je neparametarska metoda osjetljivija na moguće probleme u mjerenju (Vujčić i Jemrić, 2002).

Temeljni koncept mjerenja efikasnosti takvih entiteta je uspoređivanje omjera njihovih outputa i inputa u obliku matematičkoga modela razlomljenog linearnog programiranja koji je uveden u radu Charnes et. al. (1978):

$$Max h_0 = \sum_{j=1}^n u_j y_{jk0}$$

kao i:

$$\sum_{i=1}^m v_i x_{ik0} = 1$$

$$\sum_{j=1}^n w_j y_{jk0} \leq \sum_{i=1}^m v_i x_{ik0}$$

gdje je k broj jedinica odlučivanja, m je broj inputa, n je broj outputa. Ovaj model zove se primarni DEA model. On omogućuje da se za promatranu jedinicu odredi skup optimalnih težina w_j outputa označenih s y_j i težina v_i za inpute označene s x_i tako da se maksimizira njezina efikasnost h_0 .

Hunjak i Jakovčević (2003) navode da se u Hrvatskoj ona ne koristi šire zbog subjektivnih razloga (potrebna je dodatna edukacija menadžmenta da bi se mogao iskoristiti sav potencijal informacija koje se mogu dobiti primjenom te metode) i zbog objektivnih razloga koji proizlaze iz njezinog glavnog ograničenja; uvjet da bi se ona mogla upotrijebiti je taj da broj entiteta koji se uspoređuju mora biti barem tri puta veći od ukupnog broja inputa i outputa. Budući da ima smisla međusobno uspoređivati samo slične entitete (banke koje imaju sličnu strukturu poslovanja i djeluju u sličnom okruženju), a s obzirom na broj banaka u Hrvatskoj i mogući broj klastera ukoliko bi ih se željelo klasificirati po sličnosti, koristi od direktne primjene ove metode teško bi došle do izražaja. Realnije je očekivati uspješnu primjenu ove metode u mjerenju efikasnosti poslovnica banaka. „Kod mjerenja efikasnosti banaka i poslovnica banaka kao inputi koriste se npr. knjigovodstvena vrijednost opreme, rad (mjeren u čovjek/sati godišnje), materijalni troškovi (svi troškovi osim troškova rada i kapitala). Kao outputi mogu se koristiti ukupni depoziti, ukupni zajmovi, ukupan iznos jamstava“ (Hunjak i Jakovčević, 2003). Konačni rezultat primjene ove metode je podjela banaka (poslovnica) na one koje su efikasne (mjera njihove efikasnosti je 1) i one koje su neefikasne (njihova efikasnost je manja od 1). Iz rezultata DEA analize neposredno slijede korisne informacije za menadžment banke poput npr. što treba uraditi da bi se povećala efikasnost neefikasne banke (poslovnice) te u kojoj mjeri i uz koju cijenu je to moguće postići. Razvijen je velik broj različitih varijacija matematičkih modela za AOP analizu (Cooper, Seiford i Tone, 2000).

2.3. Prethodna istraživanja o evaluaciji performansi banaka

Ovaj dio rada predstavlja pregled dosadašnjih istraživanja provedenih na području ocjenjivanja performansi banaka. Analiza različitih pristupa i ideja pomoći će utvrđivanje najvrjednijih mjera i metodologija.

U pokušaju praćenja i procjene uspješnosti banaka, većina financijskih ekonomista i analitičari su koristili financijske pokazatelje (Ayadi et al., 1998). Najpopularnije i najčešće korišteni su povrat na kapital (ROE) i povrat na imovinu (ROA). Oni su važni pokazatelji za ocjenu

uspješnosti banaka. Međutim, korištenje samo dva pokazatelja imalo je određene nedostatke. Glavna ograničenja ROE su da može izazvati netočne rezultate zbog različite veličine poduzeća u smislu kreditnog rizika te da se trošak vlasničkog udjela ne uzima u obzir pri izračunu, te može pokazati da je uspješnost banaka dobra kada vrijednost dioničara opada (Lindblom i Von Koch.,2002). U svom radu Chapman et. al (2007) govore da se ROA susreće s tehničkim problemima kao što su: koja sredstva trebaju biti uključena u nazivnik, kako izračunati dohodak korišten u brojniku i utjecaj različitih pravila vrednovanja kao što je obračun troškova zamjene.

Studija Wirnkar i Tanko (2008) analizirala je financijske rezultate bankarskog sustava kroz 5 ključnih aspekata aktivnosti banke: adekvatnosti kapitala, kvalitete aktive, kvalitete upravljanja, sposobnosti zarade i likvidnosti.

Europska središnja banka (2010) predlaže korištenje sustava financijskih pokazatelja kombiniranih u tri kategorije:1) tradicionalne mjere uspješnosti, 2) ekonomske mjere 3) tržišne mjere učinka. Agencije za ocjenjivanje uzimaju u obzir sve vrste bonitetnih povrata kao što su kapital, kvaliteta aktive, likvidnost koja je integrirana u mjerenje performanse banke banke.

Abdelgawad i Fayek (2010) su identificirali kritične čimbenike uspjeha performanse banaka i grupirali ih u osam glavnih kategorija: 1) profitabilnost, 2) učinkovitost i produktivnost, 3) upravljanje ljudskim resursima, 4) upravljanje rizikom, 5) učinkovitost prodaje, 6) kvaliteta usluge, 7) upravljanje kapitalom i 8) konkurentno pozicioniranje. Stankevičienė i Mencaite (2012) istaknuli su da je financijski aspekt najvažniji koji utječe na poslovanje banaka. Osim toga, aspekti klijenata također su značajno doprinijeli uspješnosti bankarskog sustava.

Barros et.al., (2016) pronašli su tri važna čimbenika u poslovanju banaka: troškovi rada, troškovi kapitala i tržišni udjeli.

Nekoliko metoda višekriterijskog odlučivanja naširoko je primijenjeno u mjerenju performansi banaka. Neke od najčešće primjenjivanih tehnika uključuju Data Envelopment Analysis (DEA), Analytic Hierarchy Process (AHP), Technique for Order Preference by Similarity to Ideal Solution (TOPSIS) i Preference Ranking Organization METHod for Enrichment of Evaluation (PROMETHEE).

Nekoliko je studija primijenilo DEA modele na mjerenje učinkovitosti banaka (Parkan i Liu, 1999; Dash i Charles, 2012; Minh et al, 2013; Dash i Vegesna, 2014).

Hunjak i Jakovčević (2003) predložili su metodologiju mjerenja uspješnosti banaka na temelju višekriterijskog AHP, omogućujući razmatranje oba kvantitativna čimbenika (tj. financijske pokazatelje) i kvalitativne čimbenike (unutarnje i vanjske) u procesu evaluacije. Oni su primijenili svoj model u kontekstu hrvatskih banaka.

Stankevičienė i Mencaite (2012) koristili su model AHP za procjenu izvedbe litvanskih poslovnih banaka. Koristili su sustav indikatora i dodijelili svakom indikatoru različite težine koje odražavaju njihovo značenje na temelju potreba i prioriteta unutarnjih i vanjskih procjenitelja.

Nekoliko je studija koristilo PROMETHEE metodologiju za mjerenje uspješnosti banaka (Mareschal i Brans, 1991; Babić et.al., 1999; Doumpos i Zopounidis, 2011; Ginevičius i Podvieszko, 2013).

Opažanja i analiza literature mjerenja uspješnosti banaka jasno pokazuje da se različite tehnike i metode mogu primijeniti u ovom području mjerenja. Važno je odabrati one omjere i metode, uključujući financijske i nefinancijske mjere koje bi odražavale najtočniji pogled na bankarske aktivnosti i pomogli u rješavanju određenog problema ocjenjivanja.

3. METODE ZA VIŠEKRITERIJALNO ODLUČIVANJE I POSTAVKA PROBLEMA

3.1. Višekriterijalno odlučivanje

Definicija višekriterijalnog odlučivanja je da je to odlučivanje zasnovano na različitim kriterijima pomoću kojih se ocjenjuju različite varijante rješenja problema. Metode višekriterijalnog odlučivanja ne služe samo za isticanje jedne najpogodnije opcije, već se mogu koristiti i za rangiranje alternativa, zatim za izdvajanje alternativa koje su zadovoljavajuće, ili jednostavno za odvajanje prihvatljivih alternativa od neprihvatljivih. (Yoon, K.P., Hwang, C.L., 1995).

Zajedničke karakteristike tih problema su (Babić, Z., 2011):

1. Višestrukost kriterija

Svaki problem višekriterijalnog odlučivanja ima minimalno dva kriterija. Donosilac odluke mora izabrati relevantne kriterije kako bi donesena odluka bila kvalitetna.

2. Konflikti među kriterijima

Veći broj kriterija najčešće su u međusobnom konfliktu (suprotnosti). Tako npr. dizajniranje automobila stvara konflikt u smislu da želja za što većim rezervoarom goriva smanjuje komfor i korisni prostor za putnike.

3. Neusporedive mjerne jedinice

Kriteriji najčešće imaju različite mjerne jedinice te ih zbog toga nismo u mogućnosti usporediti. Npr. kvaliteta nekog proizvoda je izražena opisno, a cijena tog istog proizvoda brojčano.

U višekriterijalnom odlučivanju važnu ulogu igra i **donosilac odluke** čija se uloga ne može nadomjestiti niti s jednom metodom. Problemi višekriterijalnog odlučivanja mogu biti vrlo kompleksni, ne samo zbog velikog broja različitih kriterija, već i zbog različite važnosti tih kriterija. Stoga je vrlo bitno taj proces obaviti realno, objektivno i strukturno kako bi se donijele što bolje i kvalitetnije odluke.

3.2. Pojam i karakteristike metoda za procjenjivanje težine kriterija

Višekriterijalni problem sadrži više različitih, najčešće konfliktnih, kriterija koji mogu biti od različite važnosti za donosioca odluke. Za većinu metoda višekriterijalnog odlučivanja potrebne su informacije o relativnoj važnosti svakog kriterija, Relativna važnost kriterija proizlazi iz preferencija donositelja odluke na koje utječe njegov vrijednosni sustav i ostale psihološke karakteristike. Kada donosilac odluke nije zadao težine kriterija, za ocjenjivanje stupnja važnosti kriterija postoji više metoda. To mogu biti metode kod kojih odluku donosi pojedinac ili metode kod kojih odluku donosi grupa. Članovi te grupe bi trebali biti eksperti iz razmatranog područja, te jedan odgovorni donositelj odluke (Babić, Z., 2011).

U najpoznatije *grupne metode* spadaju : rangiranje, ocjenjivanje, metoda usporedbe po parovima i Delphi metoda.

Najpoznatije *metode za procjenu važnosti kriterija za individualnog donositelja odluke* su: ponderirana metoda najmanjih kvadrata, metoda entropije i metoda svojstvenog vektora koja će se koristiti u ovom radu.

Prednost grupnog donošenja odluka je širok spektar informacija, te unesena stručnost i iskustvo u analizi, a problemi koji postoje kod grupnog odlučivanja su slijedeći: potreban je dulji vremenski period nego kod individualnog donošenja odluka i dominacija autoritativnih pojedinaca koja može usmjeriti diskusiju u sasvim drugom smjeru.

3.2.1. Metoda svojstvenog vektora

Ovu metodu razvio je Thomas L. Saaty, a osim za određivanje težina kriterija koristi se i kao osnova jedne od najpoznatijih metoda za izbor najbolje alternative – AHP metode.

U ovoj metodi donosilac odluke treba prosuditi relativne važnosti kriterija tj. usporediti po važnosti sve moguće parove kriterija. Broj procjena je jednak broju kombinacija bez ponavljanja drugog razreda od n elemenata (n = broj kriterija)

$$\binom{n}{2} = \frac{n \cdot (n-1)}{2}$$

Pretpostavlja se da je donosiocu odluke lakše procijeniti relativne važnosti za svaki par kriterija, nego odjednom odrediti težine ili rangirati sve kriterije zajedno, a da bismo došli do težina kriterija potrebno je za svaki par kriterija (X_i, X_j) procijeniti njihovu relativnu važnost tako da se donosilac odluke odluči za jednu od idućih tvrdnji:

a) $a_{ij} = \frac{w_i}{w_j} = 1$ oba kriterija su jednako važna

b) $a_{ij} = \frac{w_i}{w_j} > 1$ kriterij X_i je važniji od kriterija X_j

c) $a_{ij} = \frac{w_i}{w_j} < 1$ kriterij X_j je važniji od kriterija X_i

Kod b) ili c) tvrdnje intenzitet preferencije moguće je izraziti sa više stupnjeva. Originalna skala sadrži pet stupnjeva i četiri međustupnja.

Saatyjeva skala važnosti prikazana je u sljedećoj tablici.

Tablica 3.1.Saatyjeva skala važnosti i njen opis

INTENZITET VAŽNOSTI	DEFINICIJA	OBJAŠNENJE
1	Jednaka važnost	Dva kriterija doprinose jednako danom cilju
3	Slaba preferencija jednog nad drugim	Iskustvo i prosudbe slabo favoriziraju jedan kriterij nad drugim
5	Bitna ili jaka preferencija	Iskustvo i prosudbe jako favoriziraju jedan kriterij nad drugim
7	Uvjerljiva preferencija	Jedan kriterij je u prednosti nad drugim i njegova dominacija je dokazana u praksi
9	Apsolutna preferencija	Očita prednost najvišeg mogućeg ranga jednog kriterija nad drugim
2,4,6,8	Međuvrijednosti između dviju susjednih procjena	Kada je potreban kompromis

Izvor: Babić, Z. (2011): Modeli i metode poslovnog odlučivanja, op.cit. str. 74

Pomoću skale određuju se omjeri važnosti za sve parove kriterija i formira se matrica omjera važnosti A čiji su elementi te procjene a_{ij} .

$$A = \begin{bmatrix} a_{11} & a_{12} & \dots & a_{1n} \\ a_{21} & a_{22} & \dots & a_{2n} \\ \dots & \dots & \dots & \dots \\ a_{n1} & a_{n2} & \dots & a_{nn} \end{bmatrix} = \begin{bmatrix} w_1 / w_1 & w_1 / w_2 & \dots & w_1 / w_n \\ w_2 / w_1 & w_2 / w_2 & \dots & w_2 / w_n \\ \dots & \dots & \dots & \dots \\ w_n / w_1 & w_n / w_2 & \dots & w_n / w_n \end{bmatrix}$$

gdje je

$$a_{ij} = \frac{w_i}{w_j}$$

Matrica A ima sve elemente pozitivne te za istu vrijedi svojstvo reciprociteta

$$a_{ij} = \frac{1}{a_{ji}}$$

tj. element iznad glavne dijagonale jednak je recipročnoj vrijednosti svog simetričnog elementa ispod glavne dijagonale jer vrijedi ovaj odnos:

$$\frac{w_i}{w_j} = \frac{1}{w_j / w_i}$$

Drugo svojstvo koje treba vrijediti za takvu matricu međusobnih usporedbi je da vrijedi ova relacija

$$a_{ij} = a_{ik} \cdot a_{kj}$$

Slijedeći korak je izračunavanje težina kriterija w_j koje se računaju iz matrice omjera važnosti kriterija na način da pomnožimo matricu A s vektorom težina W, odnosno:

$$A \cdot W = \begin{bmatrix} w_1 / w_1 & w_1 / w_2 & \dots & w_1 / w_n \\ w_2 / w_1 & w_2 / w_2 & \dots & w_2 / w_n \\ \dots & \dots & \dots & \dots \\ w_n / w_1 & w_n / w_2 & \dots & w_n / w_n \end{bmatrix} \cdot \begin{bmatrix} w_1 \\ w_2 \\ \vdots \\ w_n \end{bmatrix} = \begin{bmatrix} w_1 + w_1 + \dots + w_1 \\ w_2 + w_2 + \dots + w_2 \\ \dots \\ w_n + w_n + \dots + w_n \end{bmatrix} =$$

$$= n \cdot \begin{bmatrix} w_1 \\ w_2 \\ \vdots \\ w_n \end{bmatrix} = n \cdot W$$

Dobili smo jednadžbu:

$$A \cdot W = n \cdot W$$

$$\text{Odnosno: } (A - n \cdot I) \cdot W = 0$$

Matrica A ima rang 1, pa je to razlog što ima jednu svojstvenu vrijednost (realan broj λ) koja je jednaka n. U realnim procesima odlučivanja javljaju se poteškoće koje su uzrokovane nekonzistentnošću procjena relativnih omjera važnosti kriterija, što kao posljedicu ima gubitak onih svojstava omjera važnosti zbog kojih je matrica A imala samo jednu svojstvenu vrijednost. Od svih svojstvenih vrijednosti odabire se najveća, a razlika između najveće svojstvene vrijednosti matrice A i broja n služi za mjerenje konzistentnosti procjena danih u matrici A. U tu svrhu se računaju vrijednosti indeksa konzistencije (CI) i omjera konzistencije (CR):

$$CI = \frac{\lambda_{max} - n}{n - 1}$$

$$CR = CI / RI$$

RI je slučajni indeks tj. indeks konzistencije za matrice reda slučajnih generiranih usporedbi u parovima (koristi se tablica koja ima izračunate vrijednosti)

Tablica 3.2. Vrijednosti slučajnog indeksa

<i>n</i>	2	3	4	5	6	7	8	9	10
<i>RI</i>	0	0,58	0,90	1,12	1,24	1,32	1,41	1,45	1,51

Izvor: Babić, Z.(2011): Modeli i metode poslovnog odlučivanja, Ekonomski fakultet Split, Split, str.76

Pravilo: Ako za matricu A vrijedi $CR \leq 0.10$ procjene omjera relativnih važnosti kriterija se smatraju prihvatljivim. Određivanje λ_{\max} je komplicirano, a da bi sustav jednažbi $(A - n * I) * W = 0$ imao netrivialno rješenje njegova determinanta mora biti jednaka nuli. Zbog toga određivanje svojstvenih vrijednosti matrice A vodi na rješavanje jednažbe

$$\det (A - \lambda * I) = 0$$

ova algebarska jednažba n -tog stupnja nije jednostavna za rješavanje te se zbog toga za određivanje vrijednosti matrice A (i vrijednosti vektora W) koriste približne metode računanja svojstvenih vrijednosti ili gotovi softverski paketi. Težine kriterija se računaju na sljedeći način

$$(A - \lambda_{\max} * I) * W = 0$$

$$w_i > 0, i = 1, 2, \dots, n$$

$$\sum_{i=1}^n w_i = 1$$

tj. traže se rješenja sustava uz dodatne uvjete nenegativnosti i normalizacije vrijednosti komponenata rješenja. (Babić, Z., str.73-76, 2011).

3.3. Analitički hijerarhijski proces (AHP)

AHP (Saaty, 1980) spada u najpoznatije i posljednjih dvadesetak godina najviše korištene metode za odlučivanje kada se odluka (izbor neke od raspoloživih alternativa ili njihovo rangiranje) temelji na više atributa koji se koriste kao kriteriji. Rješavanje složenih problema odlučivanja pomoću ove metode temelji se na njihovoj dekompoziciji u hijerarhijsku strukturu čiji elementi su cilj, kriteriji (podkriteriji) i alternative. Druga važna komponenta AHP metode je matematički model pomoću kojega se računaju prioriteta (težine) elemenata koji su na istoj razini hijerarhijske strukture.

Primjena ove metode može se objasniti u četiri koraka:


1) Razvije se hijerarhijski model problema odlučivanja s ciljem na vrhu, kriterijima i podkriterijima na nižim razinama, te alternativama na dnu modela. Na slici je prikazan jedan takav opći model.

2) Na svakoj razini hijerarhijske strukture u parovima se međusobno uspoređuju elementi te strukture, pri čemu se preferencije donositelja odluke izražavaju uz pomoć odgovarajuće ljestvice koja ima 5 stupnjeva i 4 međustupnja verbalno opisanih intenziteta i odgovarajuće numeričke vrijednosti za njih u rasponu 1-9. U tablici 1 daje se Saaty-jeva ljestvica za usporedbe relativnih važnosti elemenata AHP modela.

3) Iz procjena relativnih važnosti elemenata odgovarajuće razine hijerarhijske strukture problema pomoću odgovarajućeg matematičkog modela izračunaju se lokalni prioriteti (težine) kriterija, podkriterija i alternativa koji se zatim sintetiziraju u ukupne prioritete alternativa.

4) Provođi se analiza osjetljivosti. Analiza osjetljivosti koristi se za određivanje osjetljivosti alternativa promjenama u prioritetima ciljeva.

Slika 3.1. Osnovni AHP model s ciljevima, kriterijima i alternativama



3.4 TOPSIS metoda

Ovu metodu su razvili Hwang i Yoon, a temelji se na tome da je najbolja alternativa ona koja ima najmanju udaljenost od idealne alternative i najveću udaljenost od antiidealne alternative. Istovremeno se razmatra udaljenost s idealnim i antiidealnim rješenjem koristeći pojam relativne bliskosti te se tako određuje konačan rang alternativa.

Dana je matrica odluke D:

$$D = \begin{matrix} & X_1 & X_2 & & X_n \\ \begin{matrix} A_1 \\ A_2 \\ \vdots \\ A_m \end{matrix} & \begin{bmatrix} x_{11} & x_{12} & \dots & x_{1n} \\ x_{21} & x_{22} & \dots & x_{2n} \\ \dots & \dots & \dots & \dots \\ x_{m1} & x_{m2} & \dots & x_{mn} \end{bmatrix} \end{matrix}$$

gdje je $\{A_1, A_2, \dots, A_m\}$ skup razmatranih alternativa, a $\{X_1, X_2, \dots, X_n\}$ skup kriterija na temelju kojih se rangiraju ili odabiru najbolje alternative.

Ova metoda pretpostavlja da su svi kriteriji ili “benefit” ili “troškovni” te ako je neki kriterij izražen opisno da ga treba kvantificirati i pretpostavlja se da postoji skup težina koji je dobiven od strane donosioca odluke.

Algoritam TOPSIS metode:

1. Korak – odrediti idealno i antiidealno rješenje

Idealna alternativa je ona koja sadrži najbolje vrijednosti po svakom atributu tj.

$$A^+ = \{ (\max x_{ij} | j \in J), (\min x_{ij} | j \in J'), i = 1, 2, \dots, m \} = \\ = \{ x_1^+, x_2^+, \dots, x_n^+ \}$$

gdje je J skup indeksa benefit, a J' skup indeksa troškovnih atributa.

Antiidealna alternativa izgleda ovako:

$$A^- = \{ (\min x_{ij} | j \in J), (\max x_{ij} | j \in J'), i = 1, 2, \dots, m \} = \\ = \{ x_1^-, x_2^-, \dots, x_n^- \}$$

Ovako napisane alternative prikazuju najviše preferiranu i najmanje preferiranu alternativu tj. idealno i anti-idealno rješenje. Ovakve alternative ne postoje unutar ponuđenog skupa jer bi to značilo da je problem već riješen.

2. Korak – Transformacija atributa

Atributi se trebaju transformirati da se dobiju bez dimenzionalne veličine kako bi se ti atributi (kriteriji) mogli usporediti. Jedan od načina transformacije je vektorska normalizacija gdje se svaki stupac u matrici –vektor X_j dijeli s normom tog vektora.

$$\overline{X_j} = \frac{X_j}{\|X_j\|} = \frac{X_j}{\sqrt{\sum_{i=1}^m x_{ij}^2}}, \quad j = 1, 2, \dots, n$$

gdje je Euklidska norma vektora $\|X_j\|$. Na taj način će novi vektori atributa svi imati jediničnu dužinu.

Time je dobivena transformirana matrica odluke $R = [r_{ij}]$, gdje je

$$r_{ij} = \frac{x_{ij}}{\sqrt{\sum_{i=1}^m x_{ij}^2}}, \quad \forall i, j.$$

Ovime su transformirani i redci matrice odluke koji postaju alternative pa imamo:

$$\overline{A_i} = (t_{i1}, t_{i2}, \dots, t_{in}) = \left(\frac{x_{i1}}{\|X_1\|}, \frac{x_{i2}}{\|X_2\|}, \dots, \frac{x_{in}}{\|X_n\|} \right), \quad \forall i = 1, \dots, m.$$

Analogno

$$\overline{A^+} = (t_1^+, t_2^+, \dots, t_n^+) = \left(\frac{x_1^+}{\|X_1\|}, \frac{x_2^+}{\|X_2\|}, \dots, \frac{x_n^+}{\|X_n\|} \right)$$

$$\overline{A^-} = (t_1^-, t_2^-, \dots, t_n^-) = \left(\frac{x_1^-}{\|X_1\|}, \frac{x_2^-}{\|X_2\|}, \dots, \frac{x_n^-}{\|X_n\|} \right)$$

3. Korak – izračunavanje udaljenosti

Ako uzmemo za pretpostavku da je skup težina dobiven od donosioca odluke dan sa:

$$W = \{w_1, w_2, \dots, w_n\}$$

možemo definirati udaljenost bilo koje alternative A od A^+ i A^- kao ponderiranu Euklidsku udaljenost na sljedeći način:

$$S_{i+} = d(A_i, A^+) = \left\| w (\bar{A}_i - \bar{A}^+) \right\| = \sqrt{\sum_{j=1}^n \left[w_j \cdot (t_{ij} - t_j^+) \right]^2} =$$

$$= \sqrt{\sum_{j=1}^n \left[\frac{w_j (x_{ij} - x_j^+)}{\|X_j\|} \right]^2}$$

Udaljenost od negativnog ideala dana je sa

$$S_{i-} = d(A_i, A^-) = \left\| w (\bar{A}_i - \bar{A}^-) \right\| = \sqrt{\sum_{j=1}^n \left[w_j \cdot (t_{ij} - t_j^-) \right]^2} =$$

$$= \sqrt{\sum_{j=1}^n \left[\frac{w_j (x_{ij} - x_j^-)}{\|X_j\|} \right]^2}$$

4. Korak – izračunavanje relativne bliskosti s idealnim rješenjem

$$RC_i = \frac{S_{i-}}{S_{i+} + S_{i-}} \rightarrow \text{Relativna bliskost alternative } A_i \text{ u odnosu na idealno rješenje } A^+$$

RC_i – indeks relativne bliskosti. Očito je $RC_i = 1$ ako je $A_i = A^+$ i $RC_i = 0$ ako je $A_i = A^-$. Alternativa je bolja - bliža idealnom rješenju što je RC_i bliži jedinici. Na kraju dobivamo konačan poredak alternativa. (Babić, Z., 2011, str.132-135).

3.5. PROMETHEE metoda

Metodu PROMETHEE (Preference Ranking Organization Method for Enrichment Evaluation) su razvili belgijski profesori J.P. Brans, B. Mareschal i P. Vincke 1984. godine s ciljem da se pomoću nje pomogne donosiocu odluke kod problema višekriterijalnog odlučivanja. Ova metoda vrši usporedbu i rangiranje više alternativa ocjenjenih na temelju više kvantitativnih i kvalitativnih kriterija. Metodu PROMETHEE I koristimo kada želimo prikazati djelomičan poredak alternativa, a metodu PROMETHEE II za potpuni poredak. Njezine prednosti su :

jednostavnost, postojanje ekonomskog objašnjenja i značaja korištenih parametara, te potpuna eliminacija efekata rangiranja. Metoda PROMETHEE spada u „ outranking “ metode.

PROMETHEE metoda je prikladna za tretirati višekriterijski problem sljedeće vrste:

$$\text{Max}\{f_1(a), \dots, f_n(a) \mid a \in K\},$$

gdje je K konačni skup mogućih akcija (ovdje banke), a f_j su n kriterija koje treba maksimizirati. Svaki kriterij je funkcija iz K u R ili u neki drugi uređeni skup.

Kad se uspoređuju dvije alternative a i b (A_k i A_l) onda trebamo taj rezultat izraziti u terminima preferencije. Tako funkcija preferencije P koja predstavlja intenzitet preferencije jedne alternative u odnosu na drugu (alternative a u odnosu na alternativu b) izgleda ovako:

$$P : A \times A \rightarrow [0, 1]$$

Definirana je na sljedeći način:

$P(a, b) = 0 \rightarrow$ indiferencija ili nepostojanje preferencije alternative a u odnosu na alternativu b

$P(a, b) \approx 0 \rightarrow$ slaba preferencija a nad b

$P(a, b) \approx 1 \rightarrow$ jaka preferencija a nad b

$P(a, b) = 1 \rightarrow$ striktna preferencija a nad b

Kažemo da se za alternative a i b određuje broj iz intervala [0, 1] koji je to bliži jedinici što je alternativa a prihvatljivija donosiocu odluke nego alternativa b. Problem je u tome što se ta prihvatljivost treba mjeriti preko više kriterija istovremeno. U praksi će funkcija preferencije biti funkcija razlike između vrijednosti (ocjena) tih dviju alternativa po nekom kriteriju.

U praksi funkcija preferencije predstavlja razliku između vrijednosti dviju alternativa uspoređenih po odgovarajućem kriteriju, tj. uvodimo novu funkciju:

$$d = f(a) - f(b)$$

Funkcija preferencije je neopadajuća funkcija, koja je jednaka nuli za negativne vrijednosti od d. Naime, ako je $d \leq 0$, tj. $f(a) \leq f(b)$, tada ne postoji preferencija od a nad b pa je i $P(a, b) = 0$. Što je razlika u ocjenama tih dviju alternativa (d), veća to je $P(a, b)$ bliži jedinici, a za određenu vrijednost od d funkcija postaje jednaka 1 jer dolazi do striktna preferencije.

Da bi imali bolji pregled područja indiferencije može se promatrati funkcija H(d) koja je direktno vezana sa funkcijom preferencije P na sljedeći način:

$$H(d) = \begin{cases} P(a,b), & d \geq 0 \\ P(b,a), & d < 0 \end{cases}$$

Za svaki kriterij f_j razmatra se zatim generalizirani kriterij definiran pomoću kriterija f_j i odgovarajuće funkcije preferencije. Metoda PROMETHEE nam nudi 6 različitih tipova funkcija preferencije. Donosilac odluke određuje koju od šest mogućih funkcija preferencije će primijeniti kod određenog kriterija. Pri tom treba odrediti parametre koji će se koristiti u nekim od funkcija i koji imaju stvarno ekonomsko značenje, a to su:

q - prag indiferencije, koji definira područje unutar kojeg je razlika vrijednosti dviju alternativa po nekom kriteriju zanemariva za donosioca odluke

p - prag preferencije, koji definira područje stroge preferencije


s - parametar čija se vrijednost nalazi između praga indiferencije q i praga preferencije p .

1. Obični kriterij

$$P(d) = \begin{cases} 0, & d \leq 0 \\ 1, & d > 0 \end{cases}$$

U ovom slučaju indiferencija između alternativa a i b postoji samo ako je $f(a) = f(b)$, tj. za $d=0$. Ako su procjene dvije alternative različite, donosilac odluke će preferirati onu koja ima veću ocjenu, pa je vrijednost funkcije preferencije jednaka 1.

Slika 3.2. Obični kriterij




2. Kvazi kriterij

$$P(d) = \begin{cases} 0, & d \leq q \\ 1, & d > q \end{cases}$$

U ovom slučaju donosilac odluke odredi vrijednost parametra q koji predstavlja prag indiferencije. Njegovo značenje je da su dvije alternative indiferentne sve dok razlika njihovih ocjena ne premaši prag q , a u protivnom postoji stroga preferencija.

Slika 3.3. Kvazi kriterij




3. Kriterij s linearnom preferencijom

$$P(d) = \begin{cases} 0, & d \leq 0 \\ \frac{d}{p}, & 0 < d < p \\ 1, & d \geq p \end{cases}$$

Kod ovog kriterija je potrebno uvesti novi parametar p koji predstavlja najnižu vrijednost od d , a iznad koje postoji stroga preferencija. Ako je vrijednost d manja od parametra p , preferencija donosioca odluke će rasti linearno s vrijednošću d . Kada razlika d postane veća od p imamo situaciju stroge preferencije. U ovom slučaju će biti potrebno da donosilac odluke odredi vrijednost parametra p – prag preferencije.

Slika 3.4. Kriterij s linearnom preferencijom




4. Nivo kriterij

$$P(d) = \begin{cases} 0 & , d \leq q \\ \frac{1}{2} & , q < d \leq p \\ 1 & , d > p \end{cases}$$

Kod ovog kriterija je potrebno da donosilac odluke istovremeno odredi oba parametra q i p . Kada se vrijednost d nalazi između pragova imamo slučaj slabe preferencije $P(d) = \frac{1}{2}$.

Slika 3.5. Nivo kriterij




5. Kriterij s linearnom preferencijom i područjem indiferencije

$$P(d) = \begin{cases} 0, & d \leq q \\ \frac{d-q}{p-q}, & q < d \leq p \\ 1, & d > p \end{cases}$$

U ovom slučaju područje koje se nalazi između pragova q i p označava da preferencija donosioca odluke raste linearno i to od područja indiferencije do područja stroge preferencije. Potrebno je istovremeno dobiti informacije od donosioca odluke za pragove q i p .

Slika 5.6. Kriterij s linearnom preferencijom i područjem indiferencije




6. Gaussov kriterij

$$P(d) = \begin{cases} 0, & d \leq 0 \\ 1 - e^{-d^2/2s^2}, & d > 0 \end{cases}$$

Kod Gaussov-og kriterija potrebno je odrediti novu vrstu parametra s koji se nalazi u području slabe preferencije, a predstavlja standardnu devijaciju normalne razdiobe. Ta funkcija koja nema prekida ni šiljaka može biti zanimljiva zbog stabilnosti rezultata.

Slika 6.7. Gaussov kriterij



Za svaki kriterij potrebno je izabrati jedan od ovih šest tipova funkcije preferencije. Nakon toga potrebno je odrediti težine (relativne važnosti) za svaki kriterij.

Potrebno je definirati indeks preferencije Π kao ponderiranu (vaganu) sredinu funkcija preferencije P_j :

$$\Pi(a, b) = \frac{\sum_{j=1}^n w_j P_j(a, b)}{\sum_{j=1}^n w_j}$$

gdje su w_j težine povezane sa svakim kriterijem.

Konačno, za svaki $a \in K$ razmotrimo dva sljedeća outranking toka:

Izlazni tok:

$$\Phi^+ = \sum_{b \in K} \Pi(a, b)$$

$$\Phi^- = \sum_{b \in K} \Pi(b, a)$$

Izlazni tok Φ^+ je mjera outranking karaktera koja izražava koliko alternativa a dominira nad ostalim alternativama. Simetrično, ulazni tok Φ^- pokazuje koliko je a dominirana od svih ostalih alternativa i po svim kriterijima što znači da se mjeri slabost alternative a u odnosu na ostale alternative. Radnja je bolja ako je izlazni tok je viši, a ulazni protok niži.

PROMETHEE I daje djelomični poredak skupa akcija u kojima su neke radnje usporedive, neke druge nisu. Kada donositelj odluke traži potpuno rangiranje, može se razmotriti neto outranking tok:

$$\Phi(a) = \Phi^+(a) - \Phi^-(a)$$

I što je veći neto tok, to je bolja radnja. Aktivnosti iz skupa K sada su potpuno rangirane (PROMETHEE II). (Babić, Z., 2011, str.152-160).

3.5. Definiranje glavnih kriterija i podkriterija

Kriteriji koji se koriste u modelu za rangiranje banaka podijeljeni su u dvije skupine koje obuhvaćaju kvantitativne pokazatelje i kvalitativna obilježja. Odabir glavnih kriterija i podkriterija temelji se na nalazima literature, ključnim pokazateljima uspješnosti Hrvatske Narodne Banke i pregledima literature.

Kao kvantitativni kriteriji, koriste se standardni financijski omjeri kao pokazatelji posebnih vidova performansi banke. Kvantitativni i financijski parametri izvedeni su razdvajanjem četiri glavna kriterija: likvidnosti, efikasnosti, profitabilnosti i adekvatnosti kapitala, a kvalitativni kriteriji odabrani su u skladu s obilježjima koja se koriste u postojećim sustavima za evaluaciju i nadzor banaka. Adekvatnost kapitala predstavlja sposobnost banke u smislu dovoljnog kapitala za apsorpiranje neočekivanih gubitaka. To je potrebno kako bi se zadržalo povjerenje deponenata i spriječilo da banka postane insolventna. Profitabilnost poslovanja posljedica je uspješnosti realizacije svih mjera poslovne politike banke. Likvidnost razmatra osjetljivost rizika kamatnih stopa, dostupnost sredstava koja se lako mogu pretvoriti u gotovinu. Efikasnost se odnosi na aktivnost bankarskih plasmana sa osnovnim ciljem da ti plasmani daju optimalne financijske efekte.

Odabrani omjeri pokrivaju sve aspekte financijskog poslovanja poduzeća, uključujući profitabilnost, solventnost i likvidnost, a ustanovljeno je da postoji i značajna razina povezanosti poslovne strategije banaka i vrijednosti promatranih financijskih omjera (Yeh, Q.J, 1996). Zbog njihove brojnosti svrstani su u podskupine za *likvidnost*, *efikasnost*, *profitabilnost* i *adekvatnost kapitala*. Ovi nazivi ukazuju koje performanse banke se mjere podkriterijima iz pojedine skupine. Pregled tih pokazatelja i njihove definicije daju se u tablici 3.3. Za uspoređivanje i rangiranje banaka važna su i obilježja za koja nisu razvijene kvantitativne metrike. U model su uključene mogućnosti procjene *kvalitete managementa* banke, očekivane *vlasničke podrške*, *značenja banke* i njezine uloge u financijskom sustavu

zemlje te *zrelosti* banke. U tablici 3.4. navode se ta obilježja i daje se kratak opis njihove uloge u modelu.

Tablica 3.3. Financijski kriteriji i podkriteriji

PROFITABILNOST	$P1 = \text{Dobit prije oporezivanja} / \text{vlastiti kapital}$ $P2 = \text{Dobit prije oporezivanja} / \text{aktiva}$ $P3 = \text{Dobit prije oporezivanja} / \text{operativni prihod}$
LIKVIDNOST	$L1 = (\text{Novac, novč. ekviv} + \text{plasmani}) / \text{ukupni depoziti}$ $L2 = \text{Ukupni krediti} / \text{ukupni depoziti}$
EFIKASNOST	$E1 = \text{Troškovi rezerviranja} / \text{neto prihod od kamata}$ $E2 = \text{Operativni prihod} / \text{ukupan broj zaposlenih}$
ADEKVATNOST KAPITALA	$C1 = \text{Ukupne obveze} / \text{vlastiti kapital}$ $C2 = \text{Ukupni depoziti} / \text{vlastiti kapital}$ $C3 = \text{Koeficijent adekvatnosti kapitala, \%}$

Kao predložak za procjenjivanje intenziteta kvalitativnih obilježja koja se u modelu koriste kao kriteriji, poslužilo je ocjenjivanje kakvo se vrši u sustavu CAMEL i jedan sustav koji se koristi u jednoj stranoj banci u svrhu odlučivanja o kupovanju udjela u bankama, a koji su prikazali u svom radu (Hunjak i Jakovčević, 2003). U tablici 3.4. navedene su indikacije za prepoznavanje pojedinih stupnjeva intenziteta kvalitativnih obilježja koja se mogu koristiti u ocjenjivanju.

Tablica 3.4. Kriteriji i intenziteti za kvalitativno rangiranje (Hunjak i Jakovčević,2003)

Intenziteti		Definicija
POTPORA		
1.	Nestabilna	Potpora vlasnika je nesigurna
2	Očekivana	Može se očekivati potpora vlasnika.
3	Sigurna	Ne treba sumnjati u potporu vlasnika.
ZNAČENJE BANKE ZA SUSTAV		
1	Mali	Banka nema značajan udio na tržištu.
2	Srednji	Banka ima značajan udio na tržištu ili pokriva potrebe značajnog dijela posebnog tržišnog segmenta.
3	Velik	Banka ima značajan udio na tržištu i njezine aktivnosti imaju utjecaj na djelovanje bankarskog sustava.
MANAGEMENT		
1	Slab	Članovi managementa često se mijenjaju, mogućnosti rješavanja problema su im male.
2	Srednji	Nema značajnijih promjena u managementu, postoji odgovarajuća administracija, rijetko dolazi do problema.
3	Jak	Nema promjena u managementu, postoji odgovarajuća administracija, ne dolazi do nepravilnosti. Problemi se rješavaju brzo i učinkovito.
STAROST ZRELOST		
1	< 5	Mlada bankarska institucija
2	5-10	Niti mlada niti zrela banka.
3	> 10	Zrela bankarska institucija.

Mogućnost preciznog izražavanja kvalitativne ocjene ovisi najviše o dostupnosti potrebnih informacija i njihovoj kvaliteti. Zbog obveze banaka da im pruže sve tražene podatke, agencije za nadzor banaka su u takvom položaju da mogu prepoznavati finije stupnjevanje u kvalitativnim kriterijima. Za rangiranje dijela hrvatskih banaka primjenom modela koji se opisuje, procjene su izvođene na temelju podataka i informacija koji su dostupni javnosti preko stručne literature i ostalih medija.

Kvaliteta sadržaja tih informacija i količina podataka ne omogućuju veću preciznost kod kvalitativnog ocjenjivanja pa se u modelu za kvalitativne kriterije koriste ljestvice sa samo tri stupnja. U tablici 3.4. opisani su stupnjevi intenziteta za kvalitativne kriterije.

3.5.1. Razvoj modela za uspoređivanje i rangiranje banaka

Može se primijetiti da primjena modela polazi od definicije kvalitativnih i kvantitativnih kriterija. Nadalje, AHP tehnika se primjenjuje kako bi se utvrdili relativni ponderi između odabranih kriterija. Rezultat primijenjenog modela biti će rangiranje banaka, pomoću PROMETHEE i TOPSIS metoda što će omogućiti ne samo ocjenjivanje banaka, nego i identificiranje boljeg učinka banaka s obzirom na banke koje bi se mogle smatrati da pokazuju nižu razinu uspješnosti (Gnanasekaran et al.,2008).

Proces primjene AHP modela počinje od uspostavljanje okvira za ocjenjivanje koji se sastoji od različitih kriterija ocjenjivanja, uključujući kvantitativne i kvalitativne mjere. Okvir evaluacije ovog istraživanja temelji se osobito na opažanjima koje je izradilo nekoliko znanstvenika koji su se bavili procjenom performansi banaka (Hunjak i Jakovčević, 2003; Stankevičienė i Mencaite, 2012) te o dodavanju dodatnih kriterija. Primjena AHP zahtijeva stvaranje hijerarhijski strukturiranog modela u kojem su osnovne skupine kriterija i pojedinačni kriteriji navedeni na različitim razinama. U ovom slučaju kvantitativni kriteriji su podijeljeni u četiri osnovne skupine: likvidnost, efikasnost, profitabilnost i adekvatnost kapitala, a kvalitativni kriteriji u četiri skupine: značenje banke za sustav, management, zrelost banke i podrška od glavnih dioničara. Svaka od spomenutih skupina na trećoj hijerarhijskoj razini dekomponirana je na pojedinačne kriterije ocjenjivanja. Predloženi AHP model sastoji se od 2 kriterija - skupine finansijskih i kvalitativnih pokazatelja, a svaka od njih sastoji se od 8 podkriterija i 10 sekundarnih podkriterija . Kriteriji, podkriteriji i sekundarni podkriteriji AHP modela prikazani su u tablici 3.3. i 3.4.

Problem identificiranja najuspješnijih komercijalnih banaka i onih koji zaostaju prema odabranom okviru procjene mogu se riješiti procjenom kriterija finansijske perspektive i kvalitativnih kriterija procjene. U ovom trenutku potrebno je formirati matricu omjera važnosti parova skupina kriterija u odnosu na glavni cilj: evaluacija performansi banaka. Kriteriji, podkriteriji i sekundarni podkriteriji procijenjeni su standardnom AHP ljestvicom na temelju procjena u parovima relativnih važnosti prema izboru autora i nalazima literature te uz pomoć

programa Super Decision izračunate su njihove težine (ponderi). Na isti način dobili smo zajedničku važnost kriterija unutar svake pojedine skupine. Međusobna usporedba je proces uspoređivanja relativne važnosti, preferencije ili vjerojatnosti dvaju elemenata s obzirom na drugi element (cilj) na razini iznad.

Težine svih kriterija i podkriterija i sekundarnih podkriterija navode se u sljedećem poglavlju.

Nakon određivanja vrijednosti težine kriterija analiza će se nastaviti metodama PROMETHEE i TOPSIS.

Podaci za studiju odnose se na uzorak od 26 komercijalnih banaka koje posluju u Republici Hrvatskoj, a koje su navedene u tablici 1.2., u razdoblju istraživanja od 2014. do 2016. godine.

Srednje financijske vrijednosti izračunate su iz Godišnjih izvješća dotičnih banaka i procijenjen je prosjek trogodišnjih omjera od 2014. do 2016. godine.

Vrijednosti financijskih pokazatelja za sve banke prikazani su u tablici 3.5.

Tablica 3.5. Vrijednosti financijskih omjera

	Profitabilnost			Likvidnost		Efikasnost		Adekvatnost kapitala		
	P1	P2	P3	L1	L2	E1	E2	C1	C2	C3
1.Addiko Bank d.d.	-0,317	-0,032	-2,558	0,248	0,923	2,065	432,182	7,004	5,654	28,47
2.Banka Kovanica	-0,039	-0,003	-0,095	0,260	0,770	0,3	575,969	9,987	9,373	14,68
3.Croatia banka d.d.	0,017	0,001	0,062	0,127	0,608	0,235	392,545	15,232	17,504	15,34
4.Erste&Steiermärkische Bank d.d.	-0,014	-0,001	-0,02	0,194	0,889	0,851	981,431	7,775	6,622	20,59
5.Hrvatska poštanska banka d.d.	-0,2	-0,007	-0,174	0,223	0,709	0,855	690,957	12,5	11,155	12,72
6.Imex banka d.d.	-0,108	0,012	-0,325	0,282	0,654	0,828	404,419	12,513	11,442	14,62
7.Istarska kreditna banka Umag d.d.	0,239	0,006	0,158	0,298	0,576	0,493	547,010	10,5	9,984	17,57
8.Jadranska banka d.d.	-6,383	-0,12	-6,162	0,273	0,576	6,425	180,188	53,879	49,762	-6,25

9.Karlovačka banka d.d.	-0,03	-0,001	-0,058	0,235	0,616	0,442	364,301	14,557	13,588	15,06
10.KentBank d.d.	-0,002	-0,001	-0,02	0,205	0,620	0,225	363,967	6,523	6,311	20,1
11.Kreditna banka Zagreb d.d.	-0,018	-0,031	-0,02	0,283	0,599	0,539	572,002	12,282	10,95	15,24
12.OTP banka Hrvatska	0,001	0,001	-0,005	0,198	0,855	0,540	548,440	8,065	7,218	16,28
13.Partner banka d.d.	0,029	0,003	0,078	0,197	0,700	0,405	545,622	8,171	6,714	16,32
14.Podravska banka d.d.	0,02	0,002	0,063	0,198	0,659	0,256	505,052	7,027	6,075	15,72
15.Primorska banka d.d.	-0,001	-0,001	-0,118	0,404	0,488	0,365	401,724	7,283	6,782	22,65
16.Privredna banka Zagreb d.d.	0,081	0,014	0,131	0,315	0,811	0,348	838,892	4,901	4,497	23,31
17.Raiffeisenbank Austria d.d.	0,043	0,007	0,131	0,242	0,765	0,548	733,578	6,097	5,276	21,55
18.Samoborska banka d.d.	-0,086	-0,012	-0,462	0,646	0,459	0,624	239,874	5,463	5,422	27,06
19.Sberbank d.d.	-0,039	-0,005	-0,168	0,281	0,854	0,640	629,040	6,474	5,797	18,96
20.Slatinska banka d.d.	-0,022	-0,002	-0,082	0,300	0,575	0,395	276,639	8,015	7,137	17,6
21.Société Générale-Splitska banka d.d.	0,081	0,011	0,261	0,324	0,809	0,327	785,975	6,624	5,642	19,18
22.Štedbanka d.d.	0,115	0,009	0,209	0,341	0,986	0,660	1285,878	1,968	1,497	41,27
23.Tesla štedna banka d.d.	-2,862	-0,816	-16,26	1,245	3,652	32,74	38,806	1,912	23,647	72,7
24.Vaba d.d.	-0,4	-0,032	-1,225	0,310	0,614	1,262	263,021	8,811	8,191	16,65
25.Veneto banka d.d.	-0,428	-0,051	-2,639	0,293	0,874	2,798	317,169	7,567	6,148	18,54
26.Zagrebačka banka d.d.	0,087	0,007	0,354	0,263	0,887	0,577	945,681	5,597	4,92	25,49
Kriterij	max	max	max	max	max	min	max	min	min	max
Najbolja vrijednost	0,239	0,014	0,354	1,245	3,652	0,225	1285,878	1,912	1,497	72,7
Najgora vrijednost	-6,383	-0,816	-16,26	0,127	0,459	32,74	38,806	53,879	49,762	-6,25

Vrijednosti kvalitativnih pokazatelja za sve banke prikazani su u tablici 3.6.

Tablica 3.6. Vrijednosti kvalitativnih pokazatelja

	Potpورا	Značenje	Menadžment	Zrelost
1.Addiko Bank d.d.	2	2	2	1
2.Banka Kovanica d.d.	2	1	2	3
3.Croatia banka d.d.	2	2	2	3
4.Erste&Steiermärkische Bank d.d.	3	3	3	3
5.Hrvatska poštanska banka d.d.	3	3	2	3
6.Imex banka d.d.	2	2	2	3
7.Istarska kreditna banka Umag d.d.	2	2	2	3
8.Jadranska banka d.d.	3	2	1	3
9.Karlovačka banka d.d.	2	2	1	3
10.KentBank d.d.	2	2	2	2
11.Kreditna banka Zagreb d.d.	2	2	2	3
12.OTP banka Hrvatska	3	3	3	3
13.Partner banka d.d.	2	2	2	3
14.Podravska banka d.d.	2	2	2	3
15.Primorska banka d.d.	2	2	2	3
16.Privredna banka Zagreb d.d.	3	3	3	3
17.Raiffeisenbank Austria d.d.	3	3	3	3
18.Samoborska banka d.d.	2	2	2	3
19.Sberbank d.d.	3	2	3	2
20.Slatinska banka d.d.	2	2	2	3
21.Société Générale-Splitska banka d.d.	2	3	2	2

22.Štedbanka d.d.	1	2	1	3
23.Tesla štedna banka d.d.	1	1	1	2
24.Vaba d.d.	1	2	1	3
25.Veneto banka d.d.	2	1	3	3
26.Zagrebačka banka d.d.	3	3	3	3

Izvor: Izrada autora

Kao što je navedeno ranije u radu kao predložak za procjenjivanje intenziteta kvalitativnih obilježja koja se u modelu koriste kao kriteriji, poslužilo je ocjenjivanje kakvo se vrši u sustavu CAMEL dakle intenzitet za svaku kategoriju i jedan sustav koji se koristi u jednoj stranoj banci u svrhu odlučivanja o kupovanju udjela u bankama, a koji su prikazali u svom radu (Hunjak i Jakovčević,2003). U tablici 3.4. navedene su indikacije za prepoznavanje pojedinih stupnjeva intenziteta kvalitativnih obilježja koja se mogu koristiti u ocjenjivanju.

Za rangiranje dijela hrvatskih banaka primjenom modela koji se opisuje, procjene su izvođene na temelju podataka i informacija koji su dostupni javnosti preko stručne literature i ostalih medija kao što su razna izvješća i publikacije koje HNB konzistentno objavljuje o poslovanju banaka koje djeluju na hrvatskom tržištu, dosadašnja istraživanja i objave o stanju u navedenim bankama, specijalizirani portali itd.

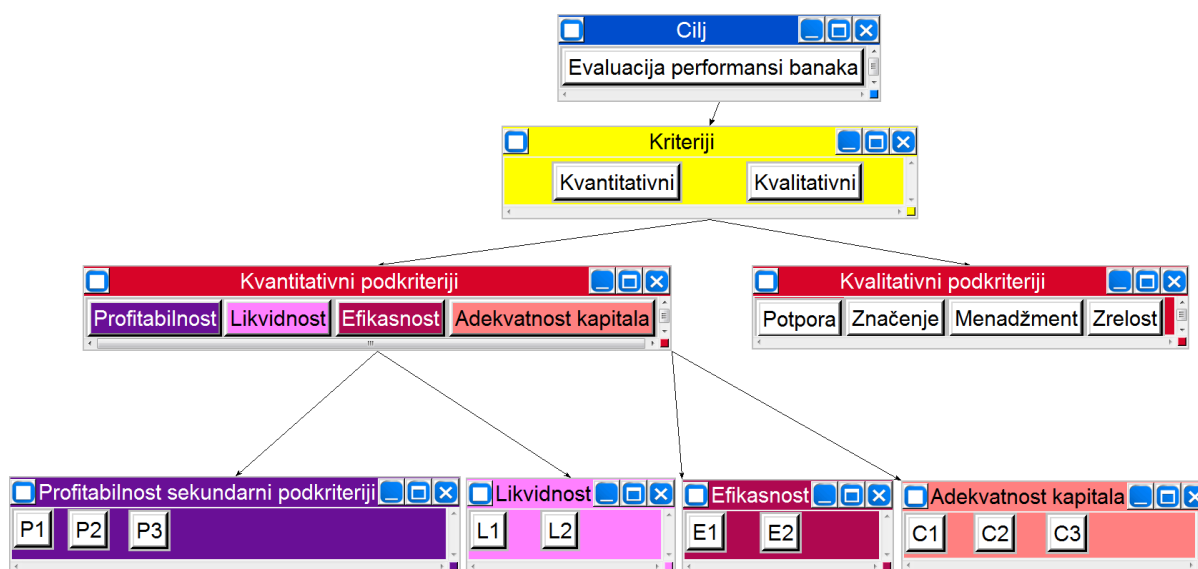
Kvaliteta sadržaja tih informacija i količina podataka ne omogućuju veću preciznost kod kvalitativnog ocjenjivanja pa se u modelu za kvalitativne kriterije koriste ljestvice sa samo tri stupnja.

4. IMPLEMENTACIJA MODELA

4.1. Procjena težina kriterija

Nakon što je formirana hijerarhija svih bitnih kriterija za proces evaluacije performansi banaka, bitno je odrediti težinu kriterija. Potrebno je i napraviti prioritetne kriterije u svim fazama. Kriteriji, podkriteriji i sekundarni podkriteriji bit će uspoređeni u parovima u odnosu na sljedeću višu hijerarhiju. Usporedbe u parovima koriste Saatyjevu skalu koja seže od jednako preferiranih do ekstremno preferiranih. Važnosti ili preferencije kriterija i podkriterija poredane su prema izboru autora i pregledu recentne literature o performansama banaka.

Slika 4.1. Potpuna hijerarhija unesena u program Super Decision





Prvi korak je poredati kriterije po važnosti. Nakon toga potrebno je formirati matricu međusobnih usporedbi navedenih kriterija, a poslije se određuju težine kriterija. Pošto hijerarhija ima tri razine kriterija mora se izračunati sve lokalne težine.

Izračun je napravljen za sve podkriterije u odnosu na kriterije i sekundarne podkriterije u odnosu na podkriterije.

Pomoću Super Decision-a se izračunavaju lokalne težine. Suma svih težina mora biti 1. Ispod glavne dijagonale nalaze se recipročne vrijednosti tj. element iznad glavne dijagonale jednak je recipročnoj vrijednosti svog simetričnog elementa ispod glavne dijagonale.

Tablica 4.1. Usporedba u parovima na drugoj razini hijerarhije

	Kvantitativni	Kvalitativni
Kvantitativni	1	3
Kvalitativni	1/3	1





Inconsistency: 0.00000		
Kvalitati~		0.25000
Kvantitat~		0.75000

Težine kriterija Kvantitativnih i Kvalitativnih su *0.25* i *0.75*

Omjer konzistentnosti *CR* govori donositelju odluke koliko je konzistentan bio tijekom uspoređivanja u parovima. Viši broj znači da je donositelj odluke bio manje konzistentan, dok niži broj govori da je bio više konzistentan. Ako je omjer konzistentnosti *CR* manji od *0.10*, onda znači da su usporedbe u paru koje je provodio donositelj odluke bile relativno konzistentne. Ako je omjer konzistentnosti *CR* veći od *0.10*, donositelj odluke bi trebao razmotriti reevaluaciju usporedbe u paru – izvori nekonzistentnosti moraju se identificirati i ukloniti te ponovno napraviti analiza.

Tablica 4.2. Usporedba u parovima kod kvantitativnih podkriterija


	Adekvatnost kapitala	Efikasnost	Likvidnost	Profitabilnost
Adekvatnost kapitala	1	1/2	1/3	1/3
Efikasnost	2	1	1/3	1/2
Likvidnost	3	3	1	2
Profitabilnost	3	2	1/2	1

Inconsistency: 0.02660		
Adekvatno~		0.10592
Efikasnost		0.16362
Likvidnost		0.44755
Profitabi~		0.28290

Težine podkriterija Adekvatnost kapitala, Efikasnost, Likvidnost i Profitabilnost su *0.106*, *0.164*, *0.447* i *0.283* u odnosu na Kvantitativni kriterij.

Tablica 4.3. Usporedba u parovima kod kvalitativnih podkriterija


	Menadžment	Potpora	Značenje	Zrelost
Menadžment	1	3	1/2	4
Potpora	1/3	1	1/4	2
Značenje	2	4	1	5
Zrelost	1/4	1/2	1/5	1

Inconsistency: 0.01811		
Menadžment		0.30557
Podrška		0.12479
Značenje		0.49184
Zrelost		0.07780

Težine podkriterija Menadžment, Potpora, Značenje i Zrelost su *0.305*, *0.125*, *0.492* i *0.078* u odnosu na Kvalitativni kriterij.

Tablica 4.4. Usporedba u parovima kod podkriterija Adekvatnost kapitala

	C1= Ukupne obveze / vlastiti kapital	C2=Ukupni depoziti / vlastiti kapital	C3=Koefficient adekvatnosti kapitala,%
C1= Ukupne obveze / vlastiti kapital	1	1/3	2
C2=Ukupni depoziti / vlastiti kapital	3	1	4
C3=Koefficient adekvatnosti kapitala,%	1/2	1/4	1



Težine sekundarnih podkriterija C1, C2, C3 su 0.238, 0.625 i 0.136 u odnosu na podkriterij Adekvatnost kapitala.

Tablica 4.5. Usporedba u parovima kod podkriterija Efikasnost

	E1=Troškovi rezerviranja / neto prihod od kamata	E2=Operativni prihod / ukupan broj zaposlenih
E1=Troškovi rezerviranja / neto prihod od kamata	1	3
E2=Operativni prihod / ukupan broj zaposlenih	1/3	1

Inconsistency: 0.00000		
E1	<div></div>	0.75000
E2	<div></div>	0.25000

Težine sekundarnih podkriterija E1 i E2 su 0.75 i 0.25 u odnosu na podkriterij Efikasnost.

Tablica 4.6. Usporedba u parovima kod podkriterija Likvidnost


	L1=(Novac, novč. ekviv + plasmani) / ukupni depoziti	L2=Ukupni krediti / ukupni depoziti
L1=(Novac, novč. ekviv + plasmani) / ukupni depoziti	1	1/4
L2=Ukupni krediti / ukupni depoziti	4	1

Inconsistency: 0.00000		
L1	<div></div>	0.20000
L2	<div></div>	0.80000

Težine sekundarnih podkriterija L1 i L2 su 0,2 i 0.8 u odnosu na podkriterij Likvidnost.

Tablica 4.7. Usporedba u parovima kod podkriterija Profitabilnost

	P1=Dobit prije oporezivanja / vlastiti kapital	P2=Dobit prije oporezivanja / aktiva	P3=Dobit prije oporezivanja / operativni prihod
P1=Dobit prije oporezivanja / vlastiti kapital	1	2	4
P2=Dobit prije oporezivanja / aktiva	1/2	1	3
P3= Dobit prije oporezivanja / operativni prihod	1/4	1/3	1



Težine sekundarnih podkriterija P1, P2 i P3 su 0.558, 0.32 i 0.122 u odnosu na podkriterij Profitabilnost.

Nakon što su izračunate sve lokalne težine potrebno je izračunati globalne težine kako bi se došlo do evaluacije performanse banaka.

Tablica 4.8. Globalne težine kriterija, podkriterija i sekundarnih podkriterija

Kvantitativni 0,75										Kvalitativni 0,25			
Profitabilnost 0,21			Likvidnost 0,34		Efikasnost 0,12		Adekvatnost kapitala 0,08			Potpura 0,03	Značenje 0,12	Menadžment 0,08	Zrelost 0,02
P1 0,05	P2 0,13	P3 0,02	L1 0,07	L2 0,27	E1 0,09	E2 0,03	C1 0,02	C2 0,05	C3 0,02				

Izvor: Izrada autora

4.2. Komparacija banaka PROMETHEE metodom

Evaluaciju komercijalnih banaka izvršit ćemo i putem PROMETHEE metode. Evaluacija pomoću AHP metode zahtijeva usporedbu u parovima banaka po svakom kriteriju. U ovom slučaju postoji 14 kriterija i 26 banaka što bi rezultiralo vrlo opsežnim modelom s velikom vjerojatnošću grešaka. Da bi se došlo do evaluacije pomoću detaljnih podataka iz ove studije slučaja koristit će se PROMETHEE metoda i na temelju prethodno odabranih kriterija i na temelju težina koje su izračunate AHP metodom u prethodnom poglavlju. PROMETHEE metoda je vrlo jednostavna u koncepciji te primjeni za razliku od drugih metoda ovakve vrste. Osim toga je i jako dobro prilagođena za probleme sa konačnim brojem alternativa koje trebaju biti rangirane uzimajući u obzir nekoliko, ponekad proturječnih kriterija (Albadvi et.al., 2007). Svakom kriteriju potrebno je odrediti funkciju preferencije. Nakon što se za svaki kriterij odabere jedna od šest funkcija preferencije potrebno je odrediti ili prag indiferencije q ili prag preferencije p ili oboje ovisno o funkciji preferencije. Osim ta dva parametra postoji i parametar s koji se nalazi između praga q i praga p koji se određuje samo za Gaussov kriterij. Svaki kriterij treba maksimizirati ili minimizirati.

Tablica 5.1. Tablica odluke kod PROMETHEE metode

Krit erij	K1	K2	K3	K4	K5	K6	K7	K8	K9	K10	K11	K12	K13	K14
Ime	P1	P2	P3	L1	L2	E1	E2	C1	C2	C3	Po po ra	Zna č enje	Menadž ment	Zrelost
Min/ Max	max	max	max	max	max	min	max	min	min	max	max	max	max	max
B1	-0,317	-0,032	-2,558	0,248	0,923	2,065	432,182	7,004	5,654	28,47	2	2	2	1
B2	-0,039	-0,003	-0,095	0,260	0,770	0,3	575,969	9,987	9,373	14,68	2	1	2	3
B3	0,017	0,001	0,062	0,127	0,608	0,235	392,545	15,232	17,504	15,34	2	2	2	3
B4	-0,014	-0,001	-0,02	0,194	0,889	0,851	981,431	7,775	6,622	20,59	3	3	3	3
B5	-0,2	-0,007	-0,174	0,223	0,709	0,855	690,957	12,5	11,155	12,72	3	3	2	3
B6	-0,108	0,012	-0,325	0,282	0,654	0,828	404,419	12,513	11,442	14,62	2	2	2	3
B7	0,239	0,006	0,158	0,298	0,576	0,493	547,010	10,5	9,984	17,57	2	2	2	3
B8	-6,383	-0,12	-6,162	0,273	0,576	6,425	180,188	53,879	49,762	-6,25	3	2	1	3
B9	-0,03	-0,001	-0,058	0,235	0,616	0,442	364,301	14,557	13,588	15,06	2	2	1	3
B10	-0,002	-0,001	-0,02	0,205	0,620	0,225	363,967	6,523	6,311	20,1	2	2	2	2
B11	-0,018	-0,031	-0,02	0,283	0,599	0,539	572,002	12,282	10,95	15,24	2	2	2	3
B12	0,001	0,001	-0,005	0,198	0,855	0,540	548,440	8,065	7,218	16,28	3	3	3	3
B13	0,029	0,003	0,078	0,197	0,700	0,405	545,622	8,171	6,714	16,32	2	2	2	3
B14	0,02	0,002	0,063	0,198	0,659	0,256	505,052	7,027	6,075	15,72	2	2	2	3
B15	-0,001	-0,001	-0,118	0,404	0,488	0,365	401,724	7,283	6,782	22,65	2	2	2	3
B16	0,081	0,014	0,131	0,315	0,811	0,348	838,892	4,901	4,497	23,31	3	3	3	3
B17	0,043	0,007	0,131	0,242	0,765	0,548	733,578	6,097	5,276	21,55	3	3	3	3
B18	-0,086	-0,012	-0,462	0,646	0,459	0,624	239,874	5,463	5,422	27,06	2	2	2	3
B19	-0,039	-0,005	-0,168	0,281	0,854	0,640	629,040	6,474	5,797	18,96	3	2	3	2
B20	-0,022	-0,002	-0,082	0,300	0,575	0,395	276,639	8,015	7,137	17,6	2	2	2	3
B21	0,081	0,011	0,261	0,324	0,809	0,327	785,975	6,624	5,642	19,18	2	3	2	2
B22	0,115	0,009	0,209	0,341	0,986	0,660	1285,878	1,968	1,497	41,27	1	2	1	3
B23	-2,862	-0,816	-16,26	1,245	3,652	32,74	38,806	1,912	23,647	72,7	1	1	1	2
B24	-0,4	-0,032	-1,225	0,310	0,614	1,262	263,021	8,811	8,191	16,65	1	2	1	3

B25	-0,428	-0,051	-2,639	0,293	0,874	2,798	317,169	7,567	6,148	18,54	2	1	3	3
B26	0,087	0,007	0,354	0,263	0,887	0,577	945,681	5,597	4,92	25,49	3	3	3	3
Teži na	0,05	0,13	0,02	0,07	0,27	0,09	0,03	0,02	0,05	0,02	0,03	0,12	0,08	0,02
Tip	3	3	3	4	5	5	5	3	3	6	4	4	4	4

Da bi se riješio problem PROMETHEE metodom koristio se program Visual Promethee. U program su uneseni podaci o 26 komercijalnih banaka (alternative B1- B26) te kriteriji (K1 – K14). Za svaki kriterij unesena je vrijednost težine. Kriterij K1, K2, K3, K4, K5, K7, K10, K11, K12 i K13 su maksimizirani dok su ostali kriteriji minimalizirani. Također su odabrane funkcije preferencije za svaki kriterij.

Za K1, K2, K3, K8 i K9 odabrana je linearna funkcija preferencije. Za ove kriterije potrebno je odrediti **p**. Za kriterije K1, K2 i K3 **p** iznosi 0,025. Preferencija raste linearno sve dok razlika u profitabilnosti ne dosegne 0,025 za sva tri kriterija. Nakon zadanih iznosa nalazi se područje stroge preferencije. Kod K8 i K9 **p** iznosi 5.

K11, K12, K13 i K14 kriteriji koriste funkciju preferencije četvrtog tipa s pragom indiferencije $q=1,5$ i pragom preferencije $p=2,5$. Dakle, ako je razlika ocjene manja od 1,5 - nema nikakve preferencije, a ako je razlika u ocjeni između 1,5 i 2,5 - imamo slabo područje preferencije čija vrijednost iznosi 0,5. Ako je razlika veća od 2,5 vrijednost funkcije preferencije jednaka je 1. K4 koristi funkciju preferencije četvrtog tipa s pragom indiferencije $q=0,1$ i pragom preferencije $p=0,15$. Dakle, ako je razlika ocjene manja od 0,1 - nema nikakve preferencije, a ako je razlika u ocjeni između 0,1 i 0,15 - imamo slabo područje preferencije čija vrijednost iznosi 0,5. Ako je razlika veća od 0,15 vrijednost funkcije preferencije jednaka je 1

Za K5, K6 i K7 odabrana je funkcija preferencije petog tipa (linearna s područjem indiferencije) Kod K5 i K6 definirani su parametri $q=0,4$ i $p=0,6$, što znači da se s razlikom od ispod 0,4 smatra indiferentnim dok razlike iznad 0,6 vode do stroge preferencije. Kod K7 parametar $q=240$ i $p=552$.

Za K10 odabran je Gaussov kriterij gdje je potrebno odrediti parametar **s**. Ovaj parametar **s** leži u području slabe preferencije i iznosi 13. Odnosno, što je razlika između dvije alternativa veća, vrijednost funkcije preferencije raste prema jedinici

Nakon provedene analize, koristeći PROMETHEE II, dobiven je konačni rang alternativa prema evaluaciji performansi banaka i prikazan je u tablici 5.2


PROMETHEE II pruža potpuno rangiranje. Prikazuje potpuni poredak alternativa i prikazuje neto tok dobiven kao razlika pozitivnog i negativnog neto toka za svaku alternativu. Što je neto tok (PHI) viši, to je bolje djelovanje (banka).

Tablica 5.2. PROMETHEE II-Kompletni poredak



























RANGIRANJE	BANKA	PHI	RANGIRANJE	BANKA	PHI
1.	B22	0,2378	14.	B18	0,0130
2.	B16	0,2140	15.	B19	0,0105
3.	B21	0,1908	16.	B23	-0,0229
4.	B26	0,1806	17.	B6	-0,0261
5.	B17	0,1453	18.	B2	-0,0320
6.	B7	0,0928	19.	B3	-0,0350
7.	B14	0,0801	20.	B9	-0,0577
8.	B13	0,0724	21.	B5	-0,0984
9.	B15	0,0697	22.	B11	-0,1204
10.	B12	0,0554	23.	B1	-0,2085
11.	B10	0,0480	24.	B24	-0,2158
12.	B4	0,0378	25.	B25	-0,2699
13.	B20	0,0171	26.	B8	-0,3785

Izvor: Izrada autora

Slika 5.1. Kompletni poredak - PROMETHEE II (Visual Promethee)



Slika 5.2. Pozitivan, negativan i neto tok za svaku alternativu

Rank	action		Phi	Phi+	Phi-
1	B22		0,2378	0,2659	0,0280
2	B16		0,2140	0,2410	0,0270
3	B21		0,1908	0,2192	0,0284
4	B26		0,1806	0,2094	0,0288
5	B17		0,1453	0,1863	0,0411
6	B7		0,0928	0,1585	0,0657
7	B14		0,0801	0,1454	0,0653
8	B13		0,0724	0,1395	0,0671
9	B15		0,0697	0,1564	0,0867
10	B12		0,0554	0,1351	0,0797
11	B10		0,0480	0,1287	0,0807
12	B4		0,0378	0,1433	0,1055
13	B20		0,0171	0,1132	0,0961
14	B18		0,0130	0,1643	0,1513
15	B19		0,0105	0,1101	0,0996
16	B23		-0,0229	0,3630	0,3858
17	B6		-0,0261	0,1172	0,1432
18	B2		-0,0320	0,1023	0,1343
19	B3		-0,0350	0,1207	0,1557
20	B9		-0,0577	0,0902	0,1479
21	B5		-0,0984	0,0865	0,1850
22	B11		-0,1204	0,0789	0,1993
23	B1		-0,2085	0,0713	0,2799
24	B24		-0,2158	0,0656	0,2814
25	B25		-0,2699	0,0526	0,3225
26	B8		-0,3785	0,0132	0,3917

Slika 5.3. Tablica odluke kod PROMETHEE metode u programu Visual Promethee

Scenario1		P1	P2	P3	L1	L2	E1	E2	C1	C2	C3	Potpura	Značenje	Menadžment	Zrelost
Unit		unit	unit	unit	unit	unit	unit	unit	unit	unit	unit	unit	unit	unit	unit
Cluster/Group		◆	◆	◆	◆	◆	◆	◆	◆	◆	◆	◆	◆	◆	◆
Preferences															
Min/Max		max	max	max	max	max	min	max	min	min	max	max	max	max	max
Weight		0,05	0,13	0,02	0,07	0,27	0,09	0,03	0,02	0,05	0,02	0,03	0,12	0,08	0,02
Preference Fn.		V-shape	V-shape	V-shape	Level	Linear	Linear	Linear	V-shape	V-shape	Gaussian	Level	Level	Level	Level
Thresholds		absolute	absolute	absolute	absolute	absolute	absolute	absolute	absolute	absolute	percentage	absolute	absolute	absolute	absolute
- Q: Indifference		n/a	n/a	n/a	0,100	0,400	0,400	239,835	n/a	n/a	n/a	1,50	1,50	1,50	1,50
- P: Preference		0,025	0,025	0,025	0,150	0,600	0,600	551,788	5,000	5,000	n/a	2,50	2,50	2,50	2,50
- S: Gaussian		n/a	n/a	n/a	n/a	n/a	n/a	n/a	n/a	n/a	13,046	n/a	n/a	n/a	n/a
Statistics															
Evaluations															
B1	🟢	-0,317	-0,032	-2,558	0,248	0,923	2,065	432,182	7,004	5,654	28,470	2,00	2,00	2,00	1,00
B2	🟢	-0,039	-0,003	-0,095	0,260	0,770	0,300	575,969	9,987	9,373	14,680	2,00	1,00	2,00	3,00
B3	🟢	0,017	0,001	0,062	0,127	0,608	0,235	392,545	15,232	17,504	15,340	2,00	2,00	2,00	3,00
B4	🟢	-0,014	-0,001	-0,020	0,194	0,889	0,851	981,431	7,775	6,622	20,590	3,00	3,00	3,00	3,00
B5	🟢	-0,200	-0,007	-0,174	0,223	0,709	0,855	690,957	12,500	11,155	12,720	3,00	3,00	2,00	3,00
B6	🟢	-0,108	0,012	-0,325	0,282	0,654	0,828	404,419	12,513	11,442	14,620	2,00	2,00	2,00	3,00
B7	🟢	0,239	0,006	0,158	0,298	0,576	0,493	547,010	10,500	9,984	17,570	2,00	2,00	2,00	3,00
B8	🟢	-6,383	-0,120	-6,162	0,273	0,576	6,425	180,188	53,879	49,762	-6,250	3,00	2,00	1,00	3,00
B9	🟢	-0,030	-0,001	-0,058	0,235	0,616	0,442	364,301	14,557	13,588	15,060	2,00	2,00	1,00	3,00
B10	🟢	-0,002	-0,001	-0,020	0,205	0,620	0,225	363,967	6,523	6,311	20,100	2,00	2,00	2,00	2,00
B11	🟢	-0,018	-0,031	-0,020	0,283	0,599	0,539	572,002	12,282	10,950	15,240	2,00	2,00	2,00	3,00
B12	🟢	0,001	0,001	-0,005	0,198	0,855	0,540	548,440	8,065	7,218	16,280	3,00	3,00	3,00	3,00
B13	🟢	0,029	0,003	0,078	0,197	0,700	0,405	545,622	8,171	6,714	16,320	2,00	2,00	2,00	3,00
B14	🟢	0,020	0,002	0,063	0,198	0,659	0,256	505,052	7,027	6,075	15,720	2,00	2,00	2,00	3,00
B15	🟢	-0,001	-0,001	-0,118	0,404	0,488	0,365	401,724	7,283	6,782	22,650	2,00	2,00	2,00	3,00
B16	🟢	0,081	0,014	0,131	0,315	0,811	0,348	838,892	4,901	4,497	23,310	3,00	3,00	3,00	3,00
B17	🟢	0,043	0,007	0,131	0,242	0,765	0,548	733,578	6,097	5,276	21,550	3,00	3,00	3,00	3,00
B18	🟢	-0,086	-0,012	-0,462	0,646	0,459	0,624	239,874	5,463	5,422	27,060	2,00	2,00	2,00	3,00
B19	🟢	-0,039	-0,005	-0,168	0,281	0,854	0,640	629,040	6,474	5,797	18,960	3,00	2,00	2,00	2,00
B20	🟢	-0,022	-0,002	-0,082	0,300	0,575	0,395	276,639	8,015	7,137	17,600	2,00	2,00	2,00	3,00
B21	🟢	0,081	0,011	0,261	0,324	0,809	0,327	785,975	6,624	5,642	19,180	2,00	3,00	3,00	2,00
B22	🟢	0,115	0,009	0,209	0,341	0,986	0,660	1285,878	1,968	1,497	41,270	1,00	2,00	2,00	3,00
B23	🟢	-2,862	-0,816	-16,260	1,245	3,652	32,740	38,806	1,912	23,647	72,700	1,00	1,00	1,00	2,00
B24	🟢	-0,400	-0,032	-1,225	0,310	0,614	1,262	263,021	8,811	8,191	16,650	1,00	2,00	2,00	3,00
B25	🟢	-0,428	-0,051	-2,639	0,293	0,874	2,798	317,169	7,567	6,148	18,540	2,00	1,00	1,00	3,00
B26	🟢	0,087	0,007	0,354	0,263	0,887	0,577	945,681	5,597	4,920	25,490	3,00	3,00	3,00	3,00

4.3. Komparacija banaka TOPSIS metodom

Svrha ove metode je naći alternativu koja je najbližnja idealnoj i najmanje slična antiidealnoj, a sličnost se odnosi na razinu udaljenosti tj. najbolja alternativa ima najmanju udaljenost od idealne i najveću udaljenost od antiidealne. Tablica odluke slična kao kod PROMETHEE metode. Analiza i proračun napravljeni u MS Excelu.

Tablica 5.3. Tablica odluke kod TOPSIS metode

Krit erij	K1	K2	K3	K4	K5	K6	K7	K8	K9	K10	K11	K12	K13	K14
Ime	P1	P2	P3	L1	L2	E1	E2	C1	C2	C3	Potp pora	Znač enje	Menadž ment	Zrelost
Min/ Max	max	max	max	max	max	min	max	min	min	max	max	max	max	max
B1	-0,317	-0,032	-2,558	0,248	0,923	2,065	432,182	7,004	5,654	28,47	2	2	2	1
B2	-0,039	-0,003	-0,095	0,260	0,770	0,3	575,969	9,987	9,373	14,68	2	1	2	3
B3	0,017	0,001	0,062	0,127	0,608	0,235	392,545	15,232	17,504	15,34	2	2	2	3
B4	-0,014	-0,001	-0,02	0,194	0,889	0,851	981,431	7,775	6,622	20,59	3	3	3	3
B5	-0,2	-0,007	-0,174	0,223	0,709	0,855	690,957	12,5	11,155	12,72	3	3	2	3
B6	-0,108	0,012	-0,325	0,282	0,654	0,828	404,419	12,513	11,442	14,62	2	2	2	3
B7	0,239	0,006	0,158	0,298	0,576	0,493	547,010	10,5	9,984	17,57	2	2	2	3
B8	-6,383	-0,12	-6,162	0,273	0,576	6,425	180,188	53,879	49,762	-6,25	3	2	1	3
B9	-0,03	-0,001	-0,058	0,235	0,616	0,442	364,301	14,557	13,588	15,06	2	2	1	3
B10	-0,002	-0,001	-0,02	0,205	0,620	0,225	363,967	6,523	6,311	20,1	2	2	2	2
B11	-0,018	-0,031	-0,02	0,283	0,599	0,539	572,002	12,282	10,95	15,24	2	2	2	3
B12	0,001	0,001	-0,005	0,198	0,855	0,540	548,440	8,065	7,218	16,28	3	3	3	3
B13	0,029	0,003	0,078	0,197	0,700	0,405	545,622	8,171	6,714	16,32	2	2	2	3
B14	0,02	0,002	0,063	0,198	0,659	0,256	505,052	7,027	6,075	15,72	2	2	2	3
B15	-0,001	-0,001	-0,118	0,404	0,488	0,365	401,724	7,283	6,782	22,65	2	2	2	3
B16	0,081	0,014	0,131	0,315	0,811	0,348	838,892	4,901	4,497	23,31	3	3	3	3
B17	0,043	0,007	0,131	0,242	0,765	0,548	733,578	6,097	5,276	21,55	3	3	3	3
B18	-0,086	-0,012	-0,462	0,646	0,459	0,624	239,874	5,463	5,422	27,06	2	2	2	3

B19	-0,039	-0,005	-0,168	0,281	0,854	0,640	629,040	6,474	5,797	18,96	3	2	3	2
B20	-0,022	-0,002	-0,082	0,300	0,575	0,395	276,639	8,015	7,137	17,6	2	2	2	3
B21	0,081	0,011	0,261	0,324	0,809	0,327	785,975	6,624	5,642	19,18	2	3	2	2
B22	0,115	0,009	0,209	0,341	0,986	0,660	1285,878	1,968	1,497	41,27	1	2	1	3
B23	-2,862	-0,816	-16,26	1,245	3,652	32,74	38,806	1,912	23,647	72,7	1	1	1	2
B24	-0,4	-0,032	-1,225	0,310	0,614	1,262	263,021	8,811	8,191	16,65	1	2	1	3
B25	-0,428	-0,051	-2,639	0,293	0,874	2,798	317,169	7,567	6,148	18,54	2	1	3	3
B26	0,087	0,007	0,354	0,263	0,887	0,577	945,681	5,597	4,92	25,49	3	3	3	3

Slika 5.4. Kvadrati i norma

KRITERIJ	K1	K2	K3	K4	K5	K6	K7	K8	K9	K10	K11	K12	K13	K14
											Podšika	Značenje	Menadžment	Zrelost
IME	P1	P2	P3	L1	L2	E1	E2	C1	C2	C3				
Min/Ma x	max	max	max	max	max	min	max	min	min	max	max	max	max	max
B1	0,1005	0,001	6,5434	0,0615	0,8519	4,2642	2E+05	49,06	31,97	810,5	4	4	4	1
B2	0,0015	9E-06	0,009	0,0676	0,5929	0,09	3E+05	99,74	87,85	215,5	4	1	4	9
B3	0,0003	1E-06	0,0038	0,0161	0,3697	0,0552	2E+05	232	306,4	235,3	4	4	4	9
B4	0,0002	1E-06	0,0004	0,0376	0,7903	0,7242	1E+06	60,45	43,85	423,9	9	9	9	9
B5	0,04	5E-05	0,0303	0,0497	0,5027	0,731	5E+05	156,3	124,4	161,8	9	9	4	9
B6	0,0117	0,0001	0,1056	0,0795	0,4277	0,6856	2E+05	156,6	130,9	213,7	4	4	4	9
B7	0,0571	4E-05	0,025	0,0888	0,3318	0,243	3E+05	110,3	99,68	308,7	4	4	4	9
B8	40,743	0,0144	37,97	0,0745	0,3318	41,281	32468	2903	2476	39,06	9	4	1	9
B9	0,0009	1E-06	0,0034	0,0552	0,3795	0,1954	1E+05	211,9	184,6	226,8	4	4	1	9
B10	4E-06	1E-06	0,0004	0,042	0,3844	0,0506	1E+05	42,55	39,83	404	4	4	4	4
B11	0,0003	0,001	0,0004	0,0801	0,3588	0,2905	3E+05	150,8	119,9	232,3	4	4	4	9
B12	1E-06	1E-06	3E-05	0,0392	0,731	0,2916	3E+05	65,04	52,1	265	9	9	9	9
B13	0,0008	9E-06	0,0061	0,0388	0,49	0,164	3E+05	66,77	45,08	266,3	4	4	4	9
B14	0,0004	4E-06	0,004	0,0392	0,4343	0,0655	3E+05	49,38	36,91	247,1	4	4	4	9
B15	1E-06	1E-06	0,0139	0,1632	0,2381	0,1332	2E+05	53,04	46	513	4	4	4	9
B16	0,0066	0,0002	0,0172	0,0992	0,6577	0,1211	7E+05	24,02	20,22	543,4	9	9	9	9
B17	0,0018	5E-05	0,0172	0,0586	0,5852	0,3003	5E+05	37,17	27,84	464,4	9	9	9	9
B18	0,0074	0,0001	0,2134	0,4173	0,2107	0,3894	57540	29,84	29,4	732,2	4	4	4	9
B19	0,0015	3E-05	0,0282	0,079	0,7293	0,4096	4E+05	41,91	33,61	359,5	9	4	9	4
B20	0,0005	4E-06	0,0067	0,09	0,3306	0,156	76529	64,24	50,94	309,8	4	4	4	9
B21	0,0066	0,0001	0,0681	0,105	0,6545	0,1069	6E+05	43,88	31,83	367,9	4	9	4	4
B22	0,0132	8E-05	0,0437	0,1163	0,9722	0,4356	2E+06	3,873	2,241	1703	1	4	1	9
B23	8,191	0,6659	264,39	5240,3	1398	1071,9	1506	3,656	559,2	5285	1	1	1	4
B24	0,16	0,001	1,5006	0,0961	0,377	1,5926	69180	77,63	67,09	277,2	1	4	1	9
B25	0,1832	0,0026	6,9643	0,0858	0,7639	7,8288	1E+05	57,26	37,8	343,7	4	1	9	9
B26	0,0076	5E-05	0,1253	0,0692	0,7868	0,3329	9E+05	31,33	24,21	649,7	9	9	9	9
SUMA	49,536	0,6868	318,09	5242,5	1411,3	1132,8	9E+06	4822	4710	15600	135	130	124	206
NORMA	7,0382	0,8287	17,835	72,405	37,567	33,658	3054	69,44	68,63	124,9	11,619	11,4	11,136	14,3527

Vektorsku transformaciju smo dobili tako da smo svaki element u tablici kvadrirali. Nakon toga smo izračunali sumu za svaki kriterij te normu koja se dobije kao korijen iz sume.

Slika 5.5. Vektorska transformacija

KRITERIJ	K1	K2	K3	K4	K5	K6	K7	K8	K9	K10	K11	K12	K13	K14
											Potpota	Značenje	Menadžment	Zrelost
IME	P1	P2	P3	L1	L2	E1	E2	C1	C2	C3				
Min/Max														
x	max	max	max	max	max	min	max	min	min	max	max	max	max	max
B1	-0,045	-0,0386	-0,1434	0,12893	0,1789	0,0614	0,14153	0,1009	0,0824	0,22795	0,172133	0,17541	0,179605302	0,07
B2	-0,006	-0,0036	-0,0053	0,13517	0,1492	0,0089	0,18862	0,1438	0,1366	0,11754	0,172133	0,08771	0,179605302	0,209
B3	0,0024	0,0012	0,0035	0,06603	0,1178	0,007	0,12855	0,2194	0,255	0,12282	0,172133	0,17541	0,179605302	0,209
B4	-0,002	-0,0012	-0,0011	0,10086	0,1723	0,0253	0,3214	0,112	0,0965	0,16485	0,258199	0,26312	0,269407953	0,209
B5	-0,028	-0,0084	-0,0098	0,11594	0,1374	0,0254	0,22628	0,18	0,1625	0,10184	0,258199	0,26312	0,179605302	0,209
B6	-0,015	0,0145	-0,0182	0,14661	0,1268	0,0246	0,13244	0,1802	0,1667	0,11706	0,172133	0,17541	0,179605302	0,209
B7	0,034	0,0072	0,0089	0,15493	0,1116	0,0146	0,17914	0,1512	0,1455	0,14067	0,172133	0,17541	0,179605302	0,209
B8	-0,907	-0,1448	-0,3455	0,14193	0,1116	0,1909	0,05901	0,7759	0,7251	-0,05004	0,258199	0,17541	0,089802651	0,209
B9	-0,004	-0,0012	-0,0033	0,12218	0,1194	0,0131	0,1193	0,2096	0,198	0,12058	0,172133	0,17541	0,089802651	0,209
B10	-3E-04	-0,0012	-0,0011	0,10658	0,1202	0,0067	0,11919	0,0939	0,092	0,16093	0,172133	0,17541	0,179605302	0,139
B11	-0,003	-0,0374	-0,0011	0,14713	0,1161	0,016	0,18732	0,1769	0,1596	0,12202	0,172133	0,17541	0,179605302	0,209
B12	0,0001	0,0012	-0,0003	0,10294	0,1657	0,016	0,17961	0,1161	0,1052	0,13035	0,258199	0,26312	0,269407953	0,209
B13	0,0041	0,0036	0,0044	0,10242	0,1357	0,012	0,17868	0,1177	0,0978	0,13067	0,172133	0,17541	0,179605302	0,209
B14	0,0028	0,0024	0,0035	0,10294	0,1277	0,0076	0,1654	0,1012	0,0885	0,12586	0,172133	0,17541	0,179605302	0,209
B15	-1E-04	-0,0012	-0,0066	0,21004	0,0946	0,0108	0,13156	0,1049	0,0988	0,18135	0,172133	0,17541	0,179605302	0,209
B16	0,0115	0,0169	0,0073	0,16377	0,1572	0,0103	0,27473	0,0706	0,0655	0,18663	0,258199	0,26312	0,269407953	0,209
B17	0,0061	0,0084	0,0073	0,12582	0,1483	0,0163	0,24024	0,0878	0,0769	0,17254	0,258199	0,26312	0,269407953	0,209
B18	-0,012	-0,0145	-0,0259	0,33585	0,089	0,0185	0,07856	0,0787	0,079	0,21666	0,172133	0,17541	0,179605302	0,209
B19	-0,006	-0,006	-0,0094	0,14609	0,1655	0,019	0,206	0,0932	0,0845	0,1518	0,258199	0,17541	0,269407953	0,139
B20	-0,003	-0,0024	-0,0046	0,15597	0,1114	0,0117	0,0906	0,1154	0,104	0,14091	0,172133	0,17541	0,179605302	0,209
B21	0,0115	0,0133	0,0146	0,16845	0,1568	0,0097	0,2574	0,0954	0,0822	0,15357	0,172133	0,26312	0,179605302	0,139
B22	0,0163	0,0109	0,0117	0,17728	0,1911	0,0196	0,42111	0,0283	0,0218	0,33043	0,086066	0,17541	0,089802651	0,209
B23	-0,407	-0,9846	-0,9117	0,64727	0,7078	0,9727	0,01271	0,0275	0,3446	0,58207	0,086066	0,08771	0,089802651	0,139
B24	-0,057	-0,0386	-0,0687	0,16117	0,119	0,0375	0,08614	0,1269	0,1193	0,13331	0,086066	0,17541	0,089802651	0,209
B25	-0,061	-0,0615	-0,148	0,15233	0,1694	0,0831	0,10387	0,109	0,0896	0,14844	0,172133	0,08771	0,269407953	0,209
B26	0,0124	0,0084	0,0198	0,13673	0,1719	0,0171	0,3097	0,0806	0,0717	0,20409	0,258199	0,26312	0,269407953	0,209
A*	0,034	0,0169	0,0198	0,64727	0,7078	0,0067	0,42111	0,0275	0,0218	0,58207	0,258199	0,26312	0,269407953	0,209
A'	-0,907	-0,9846	-0,9117	0,06603	0,089	0,9727	0,01271	0,7759	0,7251	-0,05004	0,086066	0,08771	0,089802651	0,07
Wj	0,05	0,13	0,02	0,07	0,27	0,09	0,03	0,02	0,05	0,02	0,03	0,12	0,08	0,02

Izvor: Izrada autora

Na ovoj slici 5.4. smo dobili idealnu A+ i antiidealnu alternativu A- za svaki kriterij

Slika 5.6. Udaljenost alternativa od idealne alternative

KRITERIJ	K1	K2	K3	K4	K5	K6	K7	K8	K9	K10	K11	K12	K13	K14
											Potpora	Značenje	Menadžment	Zrelost
IME	P1	P2	P3	L1	L2	E1	E2	C1	C2	C3				
Min/Max	max	max	max	max	max	min	max	min	min	max	max	max	max	max
B1	-0,0039	-0,007	-0,003	-0,036	-0,143	0,005	-0,01	0,001	0,003	-0,007	-0	-0,011	-0,0072	-0,003
B2	-0,002	-0,003	-5E-04	-0,036	-0,151	2E-04	-0,01	0,002	0,006	-0,009	-0	-0,021	-0,0072	0
B3	-0,0016	-0,002	-3E-04	-0,041	-0,159	3E-05	-0,01	0,004	0,012	-0,009	-0	-0,011	-0,0072	0
B4	-0,0018	-0,002	-4E-04	-0,038	-0,145	0,002	-0	0,002	0,004	-0,008	0	0	0	0
B5	-0,0031	-0,003	-6E-04	-0,037	-0,154	0,002	-0,01	0,003	0,007	-0,01	0	0	-0,0072	0
B6	-0,0025	-3E-04	-8E-04	-0,035	-0,157	0,002	-0,01	0,003	0,007	-0,009	-0	-0,011	-0,0072	0
B7	0	-0,001	-2E-04	-0,034	-0,161	7E-04	-0,01	0,002	0,006	-0,009	-0	-0,011	-0,0072	0
B8	-0,047	-0,021	-0,007	-0,035	-0,161	0,017	-0,01	0,015	0,035	-0,013	0	-0,011	-0,0144	0
B9	-0,0019	-0,002	-5E-04	-0,037	-0,159	6E-04	-0,01	0,004	0,009	-0,009	-0	-0,011	-0,0144	0
B10	-0,0017	-0,002	-4E-04	-0,038	-0,159	0	-0,01	0,001	0,004	-0,008	-0	-0,011	-0,0072	-0,001
B11	-0,0018	-0,007	-4E-04	-0,035	-0,16	8E-04	-0,01	0,003	0,007	-0,009	-0	-0,011	-0,0072	0
B12	-0,0017	-0,002	-4E-04	-0,038	-0,146	8E-04	-0,01	0,002	0,004	-0,009	0	0	0	0
B13	-0,0015	-0,002	-3E-04	-0,038	-0,154	5E-04	-0,01	0,002	0,004	-0,009	-0	-0,011	-0,0072	0
B14	-0,0016	-0,002	-3E-04	-0,038	-0,157	8E-05	-0,01	0,001	0,003	-0,009	-0	-0,011	-0,0072	0
B15	-0,0017	-0,002	-5E-04	-0,031	-0,166	4E-04	-0,01	0,002	0,004	-0,008	-0	-0,011	-0,0072	0
B16	-0,0011	0	-3E-04	-0,034	-0,149	3E-04	-0	9E-04	0,002	-0,008	0	0	0	0
B17	-0,0014	-0,001	-3E-04	-0,037	-0,151	9E-04	-0,01	0,001	0,003	-0,008	0	0	0	0
B18	-0,0023	-0,004	-9E-04	-0,022	-0,167	0,001	-0,01	0,001	0,003	-0,007	-0	-0,011	-0,0072	0
B19	-0,002	-0,003	-6E-04	-0,035	-0,146	0,001	-0,01	0,001	0,003	-0,009	0	-0,011	0	-0,001
B20	-0,0019	-0,003	-5E-04	-0,034	-0,161	5E-04	-0,01	0,002	0,004	-0,009	-0	-0,011	-0,0072	0
B21	-0,0011	-5E-04	-1E-04	-0,034	-0,149	3E-04	-0	0,001	0,003	-0,009	-0	0	-0,0072	-0,001
B22	-0,0009	-8E-04	-2E-04	-0,033	-0,14	0,001	0	2E-05	0	-0,005	-0,01	-0,011	-0,0144	0
B23	-0,022	-0,13	-0,019	0	0	0,087	-0,01	0	0,016	0	-0,01	-0,021	-0,0144	-0,001
B24	-0,0045	-0,007	-0,002	-0,034	-0,159	0,003	-0,01	0,002	0,005	-0,009	-0,01	-0,011	-0,0144	0
B25	-0,0047	-0,01	-0,003	-0,035	-0,145	0,007	-0,01	0,002	0,003	-0,009	-0	-0,021	0	0
B26	-0,0011	-0,001	0	-0,036	-0,145	9E-04	-0	0,001	0,002	-0,008	0	0	0	0

Izvor: Izrada autora

Na slici 5.5. smo izračunali udaljenost od Si+ tako da smo težinu svakog kriterija pomnožili sa vrijednošću dobivenoj u vektorskoj transformaciji koja je umanjena za idealnu alternativu A+.

Podaci na slici 5.5. se kvadriraju kako bi se kasnije izračunala relativna bliskost i dobio konačan poredak alternativa. Suma se dobije kao zbroj svih kriterija kod svake pojedine alternative. Si + se dobije kao korijen od sume.

Slika 5.7. Kvadrati, suma i $S_i +$

KRITERIJ	K1	K2	K3	K4	K5	K6	K7	K8	K9	K10	K11	K12	K13	K14		
											Potpota	Značenje	Međanđment	Zrelost		
IME	P1	P2	P3	L1	L2	E1	E2	C1	C2	C3						
Min/Max	max	max	max	max	max	min	max	min	min	max	max	max	max	max	SUMA	$S_i +$
B1	1,56E-05	5,2E-05	1,1E-05	0,0013	0,0204	2,4E-05	7E-05	2,2E-06	9,2E-06	5E-05	6,7E-06	0,00011	5,2E-05	7,8E-06	0,0221	0,14874
B2	3,9E-06	7,1E-06	2,5E-07	0,0013	0,02275	4E-08	4,9E-05	5,4E-06	3,3E-05	8,6E-05	6,7E-06	0,00044	5,2E-05	0	0,0247	0,15722
B3	2,49E-06	4,2E-06	1,1E-07	0,0017	0,02538	7,2E-10	7,7E-05	1,5E-05	0,00014	8,4E-05	6,7E-06	0,00011	5,2E-05	0	0,0275	0,16589
B4	3,23E-06	5,5E-06	1,8E-07	0,0015	0,02091	2,8E-06	8,9E-06	2,9E-06	1,4E-05	7E-05	0	0	0	0	0,0225	0,14992
B5	9,73E-06	1,1E-05	3,5E-07	0,0014	0,02372	2,8E-06	3,4E-05	9,3E-06	5E-05	9,2E-05	0	0	5,2E-05	0	0,0254	0,15926
B6	6,08E-06	9,8E-08	5,8E-07	0,0012	0,02461	2,6E-06	7,5E-05	9,3E-06	5,2E-05	8,6E-05	6,7E-06	0,00011	5,2E-05	0	0,0262	0,162
B7	0	1,6E-06	4,8E-08	0,0012	0,02591	5,1E-07	5,3E-05	6,1E-06	3,8E-05	7,8E-05	6,7E-06	0,00011	5,2E-05	0	0,0274	0,16567
B8	0,002213	0,00044	5,3E-05	0,0013	0,02591	0,00027	0,00012	0,00022	0,00124	0,00016	0	0,00011	0,00021	0	0,0322	0,17945
B9	3,65E-06	5,5E-06	2,1E-07	0,0014	0,02524	3,4E-07	8,2E-05	1,3E-05	7,8E-05	8,5E-05	6,7E-06	0,00011	0,00021	0	0,0272	0,16488
B10	2,93E-06	5,5E-06	1,8E-07	0,0014	0,02518	0	8,2E-05	1,8E-06	1,2E-05	7,1E-05	6,7E-06	0,00011	5,2E-05	1,9E-06	0,027	0,16418
B11	3,33E-06	5E-05	1,8E-07	0,0012	0,02553	7E-07	4,9E-05	8,9E-06	4,7E-05	8,5E-05	6,7E-06	0,00011	5,2E-05	0	0,0272	0,16482
B12	2,86E-06	4,2E-06	1,6E-07	0,0015	0,02142	7,1E-07	5,2E-05	3,1E-06	1,7E-05	8,2E-05	0	0	0	0	0,023	0,15178
B13	2,23E-06	3E-06	9,6E-08	0,0015	0,02386	2,3E-07	5,3E-05	3,2E-06	1,4E-05	8,2E-05	6,7E-06	0,00011	5,2E-05	0	0,0256	0,16014
B14	2,42E-06	3,5E-06	1,1E-07	0,0015	0,02453	6,9E-09	5,9E-05	2,2E-06	1,1E-05	8,3E-05	6,7E-06	0,00011	5,2E-05	0	0,0263	0,16222
B15	2,91E-06	5,5E-06	2,8E-07	0,0009	0,02742	1,4E-07	7,5E-05	2,4E-06	1,5E-05	6,4E-05	6,7E-06	0,00011	5,2E-05	0	0,0287	0,16937
B16	1,26E-06	0	6,3E-08	0,0011	0,0221	1,1E-07	1,9E-05	7,4E-07	4,8E-06	6,3E-05	0	0	0	0	0,0233	0,15277
B17	1,94E-06	1,2E-06	6,3E-08	0,0013	0,02283	7,5E-07	2,9E-05	1,5E-06	7,6E-06	6,7E-05	0	0	0	0	0,0243	0,15578
B18	5,33E-06	1,7E-05	8,4E-07	0,0005	0,02792	1,1E-06	0,00011	1E-06	8,2E-06	5,3E-05	6,7E-06	0,00011	5,2E-05	0	0,0288	0,16958
B19	3,9E-06	8,9E-06	3,4E-07	0,0012	0,02144	1,2E-06	4,2E-05	1,7E-06	9,8E-06	7,4E-05	0	0,00011	0	1,9E-06	0,0229	0,15141
B20	3,44E-06	6,3E-06	2,4E-07	0,0012	0,02593	2,1E-07	9,8E-05	3,1E-06	1,7E-05	7,8E-05	6,7E-06	0,00011	5,2E-05	0	0,0275	0,16579
B21	1,26E-06	2,2E-07	1,1E-08	0,0011	0,02213	7,4E-08	2,4E-05	1,8E-06	9,1E-06	7,3E-05	6,7E-06	0	5,2E-05	1,9E-06	0,0234	0,15306
B22	7,76E-07	6,2E-07	2,6E-08	0,0011	0,01946	1,4E-06	0	2,6E-10	0	2,5E-05	2,7E-05	0,00011	0,00021	0	0,0209	0,14463
B23	0,000485	0,01695	0,00035	0	0	0,00756	0,00015	0	0,00026	0	2,7E-05	0,00044	0,00021	1,9E-06	0,0264	0,16258
B24	2,06E-05	5,2E-05	3,1E-06	0,0012	0,02528	7,7E-06	0,0001	3,9E-06	2,4E-05	8,1E-05	2,7E-05	0,00011	0,00021	0	0,0271	0,16453
B25	2,25E-05	0,0001	1,1E-05	0,0012	0,02113	4,7E-05	9,1E-05	2,7E-06	1,1E-05	7,5E-05	6,7E-06	0,00044	0	0	0,0231	0,15215
B26	1,17E-06	1,2E-06	0	0,0013	0,02094	8,9E-07	1,1E-05	1,1E-06	6,2E-06	5,7E-05	0	0	0	0	0,0223	0,14931

Izvor: Izrada autora

Slika 5.8. Udaljenost alternativa od antiidealne alternative

KRITERIJ	K1	K2	K3	K4	K5	K6	K7	K8	K9	K10	K11	K12	K13	K14
											Poljora	Značenje	Menadžment	Zrelost
IME	P1	P2	P3	L1	L2	E1	E2	C1	C2	C3				
Min/Max	max	max	max	max	max	min	max	min	min	max	max	max	max	max
B1	0,04309	0,123	0,0154	0,0044	0,0243	-0,08	0,004	-0,014	-0,032	0,0056	0,003	0,0105	0,00718	0
B2	0,04507	0,1275	0,0181	0,0048	0,0163	-0,09	0,005	-0,013	-0,029	0,0034	0,003	0	0,00718	0,0028
B3	0,04547	0,1282	0,0183	0	0,0078	-0,09	0,003	-0,011	-0,024	0,0035	0,003	0,0105	0,00718	0,0028
B4	0,04525	0,1278	0,0182	0,0024	0,0225	-0,09	0,009	-0,013	-0,031	0,0043	0,005	0,021	0,01437	0,0028
B5	0,04392	0,1269	0,018	0,0035	0,0131	-0,09	0,006	-0,012	-0,028	0,003	0,005	0,021	0,00718	0,0028
B6	0,04458	0,1299	0,0179	0,0056	0,0102	-0,09	0,004	-0,012	-0,028	0,0033	0,003	0,0105	0,00718	0,0028
B7	0,04704	0,1289	0,0184	0,0062	0,0061	-0,09	0,005	-0,012	-0,029	0,0038	0,003	0,0105	0,00718	0,0028
B8	0	0,1092	0,0113	0,0053	0,0061	-0,07	0,001	0	0	0	0,005	0,0105	0	0,0028
B9	0,04513	0,1278	0,0182	0,0039	0,0082	-0,09	0,003	-0,011	-0,026	0,0034	0,003	0,0105	0	0,0028
B10	0,04533	0,1278	0,0182	0,0028	0,0084	-0,09	0,003	-0,014	-0,032	0,0042	0,003	0,0105	0,00718	0,0014
B11	0,04522	0,1231	0,0182	0,0057	0,0073	-0,09	0,005	-0,012	-0,028	0,0034	0,003	0,0105	0,00718	0,0028
B12	0,04535	0,1282	0,0182	0,0026	0,0207	-0,09	0,005	-0,013	-0,031	0,0036	0,005	0,021	0,01437	0,0028
B13	0,04555	0,1285	0,0183	0,0025	0,0126	-0,09	0,005	-0,013	-0,031	0,0036	0,003	0,0105	0,00718	0,0028
B14	0,04549	0,1283	0,0183	0,0026	0,0105	-0,09	0,005	-0,013	-0,032	0,0035	0,003	0,0105	0,00718	0,0028
B15	0,04534	0,1278	0,0181	0,0101	0,0015	-0,09	0,004	-0,013	-0,031	0,0046	0,003	0,0105	0,00718	0,0028
B16	0,04592	0,1302	0,0184	0,0068	0,0184	-0,09	0,008	-0,014	-0,033	0,0047	0,005	0,021	0,01437	0,0028
B17	0,04565	0,1291	0,0184	0,0042	0,016	-0,09	0,007	-0,014	-0,032	0,0045	0,005	0,021	0,01437	0,0028
B18	0,04473	0,1261	0,0177	0,0189	0	-0,09	0,002	-0,014	-0,032	0,0053	0,003	0,0105	0,00718	0,0028
B19	0,04507	0,1272	0,018	0,0056	0,0207	-0,09	0,006	-0,014	-0,032	0,004	0,005	0,0105	0,01437	0,0014
B20	0,04519	0,1277	0,0181	0,0063	0,0061	-0,09	0,002	-0,013	-0,031	0,0038	0,003	0,0105	0,00718	0,0028
B21	0,04592	0,1297	0,0185	0,0072	0,0183	-0,09	0,007	-0,014	-0,032	0,0041	0,003	0,021	0,00718	0,0014
B22	0,04616	0,1294	0,0185	0,0078	0,0276	-0,09	0,012	-0,015	-0,035	0,0076	0	0,0105	0	0,0028
B23	0,02501	0	0	0,0407	0,1671	0	0	-0,015	-0,019	0,0126	0	0	0	0,0014
B24	0,0425	0,123	0,0169	0,0067	0,0081	-0,08	0,002	-0,013	-0,03	0,0037	0	0,0105	0	0,0028
B25	0,04231	0,12	0,0153	0,006	0,0217	-0,08	0,003	-0,013	-0,032	0,004	0,003	0	0,01437	0,0028
B26	0,04596	0,1291	0,0186	0,0049	0,0224	-0,09	0,009	-0,014	-0,033	0,0051	0,005	0,021	0,01437	0,0028

Izvor: Izrada autora

Na slici 5.6. smo izračunali udaljenost od Si- tako da smo težinu svakog kriterija pomnožili sa vrijednošću dobivenoj u vektorskoj transformaciji koja je umanjena za antiidealnu alternativu A-.

Podaci na slici 5.6. se kvadriraju kako bi se kasnije izračunala relativna bliskost i dobio konačan poredak alternativa. Suma se dobije kao zbroj svih kriterija kod svake pojedine alternative. Si - se dobije kao korijen od sume. Prikaz na slici 5.7.

Slika 5.9. Kvadrati, suma i Si –

KRITERIJ	K1	K2	K3	K4	K5	K6	K7	K8	K9	K10	K11	K12	K13	K14		
											Potpora	Značenje	Menadžment	Zrelost		
IME	P1	P2	P3	L1	L2	E1	E2	C1	C2	C3						
Min/Max	max	max	max	max	max	min	max	min	min	max	max	max	max	max	SUMA	Si-
B1	0,001857	0,01512	0,00024	2E-05	0,00059	0,00673	1,5E-05	0,00018	0,00103	3,1E-05	6,7E-06	0,00011	5,2E-05	0	0,026	0,1612
B2	0,002031	0,01626	0,00033	2E-05	0,00026	0,00752	2,8E-05	0,00016	0,00087	1,1E-05	6,7E-06	0	5,2E-05	7,8E-06	0,0276	0,16604
B3	0,002067	0,01643	0,00034	0	6,1E-05	0,00755	1,2E-05	0,00012	0,00055	1,2E-05	6,7E-06	0,00011	5,2E-05	7,8E-06	0,0273	0,16529
B4	0,002047	0,01634	0,00033	6E-06	0,00051	0,00727	8,6E-05	0,00018	0,00099	1,8E-05	2,7E-05	0,00044	0,00021	7,8E-06	0,0285	0,1687
B5	0,001929	0,0161	0,00033	1E-05	0,00017	0,00727	4,1E-05	0,00014	0,00079	9,2E-06	2,7E-05	0,00044	5,2E-05	7,8E-06	0,0273	0,1653
B6	0,001987	0,01687	0,00032	3E-05	0,0001	0,00728	1,3E-05	0,00014	0,00078	1,1E-05	6,7E-06	0,00011	5,2E-05	7,8E-06	0,0277	0,16648
B7	0,002213	0,01663	0,00034	4E-05	3,7E-05	0,00744	2,5E-05	0,00016	0,00084	1,5E-05	6,7E-06	0,00011	5,2E-05	7,8E-06	0,0279	0,16704
B8	0	0,01192	0,00013	3E-05	3,7E-05	0,00495	1,9E-06	0	0	0	2,7E-05	0,00011	0	7,8E-06	0,0172	0,1312
B9	0,002037	0,01634	0,00033	2E-05	6,8E-05	0,00746	1E-05	0,00013	0,00069	1,2E-05	6,7E-06	0,00011	0	7,8E-06	0,0272	0,16499
B10	0,002055	0,01634	0,00033	8E-06	7,1E-05	0,00756	1E-05	0,00019	0,001	1,8E-05	6,7E-06	0,00011	5,2E-05	1,9E-06	0,0278	0,1666
B11	0,002045	0,01516	0,00033	3E-05	5,4E-05	0,00741	2,7E-05	0,00014	0,0008	1,2E-05	6,7E-06	0,00011	5,2E-05	7,8E-06	0,0262	0,16186
B12	0,002057	0,01643	0,00033	7E-06	0,00043	0,00741	2,5E-05	0,00017	0,00096	1,3E-05	2,7E-05	0,00044	0,00021	7,8E-06	0,0285	0,16888
B13	0,002075	0,01651	0,00034	6E-06	0,00016	0,00748	2,5E-05	0,00017	0,00098	1,3E-05	6,7E-06	0,00011	5,2E-05	7,8E-06	0,0279	0,16712
B14	0,002069	0,01647	0,00034	7E-06	0,00011	0,00754	2,1E-05	0,00018	0,00101	1,2E-05	6,7E-06	0,00011	5,2E-05	7,8E-06	0,0279	0,16714
B15	0,002056	0,01634	0,00033	0,0001	2,3E-06	0,00749	1,3E-05	0,00018	0,00098	2,1E-05	6,7E-06	0,00011	5,2E-05	7,8E-06	0,0277	0,16643
B16	0,002109	0,01695	0,00034	5E-05	0,00034	0,0075	6,2E-05	0,0002	0,00109	2,2E-05	2,7E-05	0,00044	0,00021	7,8E-06	0,0293	0,17129
B17	0,002084	0,01667	0,00034	2E-05	0,00026	0,00741	4,7E-05	0,00019	0,00105	2E-05	2,7E-05	0,00044	0,00021	7,8E-06	0,0288	0,1696
B18	0,002001	0,01591	0,00031	0,0004	0	0,00737	3,9E-06	0,00019	0,00104	2,8E-05	6,7E-06	0,00011	5,2E-05	7,8E-06	0,0274	0,16553
B19	0,002031	0,01618	0,00033	3E-05	0,00043	0,00737	3,4E-05	0,00019	0,00103	1,6E-05	2,7E-05	0,00011	0,00021	1,9E-06	0,028	0,16726
B20	0,002042	0,0163	0,00033	4E-05	3,7E-05	0,00748	5,5E-06	0,00017	0,00096	1,5E-05	6,7E-06	0,00011	5,2E-05	7,8E-06	0,0276	0,16604
B21	0,002109	0,01683	0,00034	5E-05	0,00034	0,00751	5,4E-05	0,00019	0,00103	1,7E-05	6,7E-06	0,00044	5,2E-05	1,9E-06	0,029	0,17021
B22	0,002131	0,01675	0,00034	6E-05	0,00076	0,00736	0,00015	0,00022	0,00124	5,8E-05	0	0,00011	0	7,8E-06	0,0292	0,17084
B23	0,000626	0	0	0,0017	0,02792	0	0	0,00022	0,00036	0,00016	0	0	0	1,9E-06	0,0309	0,17592
B24	0,001807	0,01512	0,00028	4E-05	6,6E-05	0,00708	4,9E-06	0,00017	0,00092	1,3E-05	0	0,00011	0	7,8E-06	0,0256	0,1601
B25	0,00179	0,0144	0,00023	4E-05	0,00047	0,00641	7,5E-06	0,00018	0,00101	1,6E-05	6,7E-06	0	0,00021	7,8E-06	0,0248	0,1574
B26	0,002113	0,01667	0,00035	2E-05	0,0005	0,0074	7,9E-05	0,00019	0,00107	2,6E-05	2,7E-05	0,00044	0,00021	7,8E-06	0,0291	0,17059

Izvor: Izrada autora

U sljedećoj tablici 5.4. izračunava se indeks relativne bliskosti RC_i te rangiraju alternative.

Tablica 5.4. Relativna bliskost i konačan poredak alternativa

	RCi		RCi		RCi
B22	0,54154	B23	0,51971	B20	0,50037
B26	0,53326	B2	0,51364	B9	0,50018
B4	0,52947	B13	0,51066	B3	0,49909
B16	0,52858	B5	0,50931	B15	0,49561
B12	0,52666	B25	0,50848	B11	0,49548
B21	0,52652	B14	0,50747	B18	0,49396
B19	0,52487	B6	0,50682	B24	0,49318
B17	0,52123	B10	0,50366	B8	0,42234
B1	0,52010	B7	0,50206		

Izvor: Izrada autora

Izračunom relativne bliskosti može se uočiti kako je najbolja alternativa B22, a zatim slijede B26, B4, B16 itd., te kao posljednja B8.

4.4. Usporedba rezultata dobivenih PROMETHEE metodom i TOPSIS metodom

Tablica 5.5. Komparacija poretka banaka kod PROMETHEE i TOPSIS metode

PROMETHEE	TOPSIS
B22 (Štedbanka d.d.)	B22 (Štedbanka d.d.)
B16 (PBZ d.d.)	B26 (Zagrebačka banka d.d.)
B21 (Société Générale-Splitska banka d.d.)	B4 (Erste&Steiermärkische Bank d.d.)
B26 (Zagrebačka banka d.d.)	B16 (PBZ d.d.)
B17 (Raiffeisenbank Austria d.d.)	B12 (OTP banka Hrvatska d.d.)
B7 (Istarska kreditna banka Umag d.d.)	B21 (Société Générale-Splitska banka d.d.)
B14 (Podravska banka d.d.)	B19 (Sberbank d.d.)
B13 (Partner banka d.d.)	B17 (Raiffeisenbank Austria d.d.)
B15 (Primorska banka d.d.)	B1 (Addiko Bank d.d.)
B12 (OTP banka Hrvatska d.d.)	B23 (Tesla štedna banka d.d.)
B10 (KentBank d.d.)	B2 (Banka Kovanica d.d.)

B4 (Erste&Steiermärkische Bank d.d.)	B13 (Partner banka d.d.)
B20 (Slatinska banka d.d.)	B5 (Hrvatska poštanska banka d.d.)
B18 (Samoborska banka d.d.)	B25 (Veneto banka d.d.)
B19 (Sberbank d.d.)	B14 (Podravska banka d.d.)
B23 (Tesla štedna banka d.d.)	B6 (Imex banka d.d.)
B6 (Imex banka d.d.)	B10 (KentBank d.d.)
B2 (Banka Kovanica d.d.)	B7 (Istarska kreditna banka Umag d.d.)
B3 (Croatia banka d.d.)	B20 (Slatinska banka d.d.)
B9 (Karlovačka banka d.d.)	B9 (Karlovačka banka d.d.)
B5 (Hrvatska poštanska banka d.d.)	B3 (Croatia banka d.d.)
B11 (Kreditna banka Zagreb d.d.)	B15 (Primorska banka d.d.)
B1 (Addiko Bank d.d.)	B11 (Kreditna banka Zagreb d.d.)
B24 (Vaba d.d.)	B18 (Samoborska banka d.d.)
B25 (Veneto banka d.d.)	B24 (Vaba d.d.)
B8 (Jadranska banka d.d.)	B8 (Jadranska banka d.d.)

Izvor: Izrada autora

Analizom i usporedbom rezultata jasno se uočava da postoji određena razlika između metoda u rangiranju banaka. Rezultati su isti kod rangiranja prve i posljednje alternative, ali se razlikuju kod rangiranja alternativa koje se nalaze između te dvije. Kod TOPSIS metode najviše pozicionirane su banke s najznačajnijim dijelom hrvatske bankarske aktive i tržišnog udjela. Međutim kod PROMETHEE i TOPSIS metode najviše pozicionirana banka (Štedbanka) se u razdobljima koja se odnose nakon razdoblja koje obuhvaća ovo istraživanje našla u ozbiljnim poslovnim problemima koji su doveli do njene likvidacije. Ova stavka ukazuje na moguću upotrebu dodatnih kriterija kao i drugih metoda s više osjetljivijim instrumentima mjerenja, ali ovi modeli su pokazali kompleksnost problema evaluacije performansi banaka te važnost razvoja i primjene višekriterijskih modela kojima se nastoji obuhvatiti sve moguće razloge, kriterije i komplikacije inače vrlo složenog i zamršenog poslovnog okruženja u kojem djeluju banke.

ZAKLJUČAK

Evaluacija performansi banaka je složen financijski problem koji je od velikog interesa za praktičare i razne istraživače. Ove financijske institucije upravljaju značajnim udjelom sredstava u cjelokupnom financijskom sustavu i njihov učinak zajedno s cjelokupnim stanjem ima veliki utjecaj na stabilnost financijskog sustava kao i stabilnost nacionalnog gospodarstva. Bankarstvo kao grana industrije prošlo je put značajnih promjena tijekom posljednjih desetljeća. Poslovni modeli i procesi postali su višestruki i broj usluga i područja djelatnosti povećao se nekoliko puta. Svi ti faktori doveli su do situacije koja pokazuje da je mjerenje uspješnosti banaka postalo više sofisticiranije i kao rezultat potrebe za metodologijom koja u potpunosti odražava različite aspekte uspješnosti i zadovoljavanju različitih interesa klijenata, investitora, nadzornih tijela i uprava banke je došla u prvi plan. Kriteriji koji se pritom koriste različite su važnosti, a mogu biti kvantitativni i kvalitativni. Kompleksnost problema evaluacije performansi banaka otežava razvoj i primjenu standardnih modela i predstavlja motivaciju za razvoj novih, fleksibilnijih modela koje je moguće prilagoditi specifičnim interesnim stajalištima onih koji uspoređuju banke. Upravo se zbog toga u ovom radu uvode višekriterijski modeli kojima se nastoji obuhvatiti sve moguće razloge, kriterije i komplikacije inače vrlo složenog i zamršenog poslovnog okruženja u kojem djeluju banke.

Model je uveden kako bi se osim uobičajenih financijskih pokazatelja kao što su ROA i ROE uključilo dodatne financijske kriterije te značajne nefinancijske aspekte u okvir evaluacije. Ovaj model omogućuje podjelu problema ocjenjivanja uspješnosti banaka na četiri glavne faze kao što su definiranje kvalitativnih i kvantitativnih kriterija, osnivanje okvira vrednovanja, stjecanje relativnih i globalnih težina kriterija i podkriterija korištenjem AHP-a te rangiranje alternativa pomoću PROMETHEE i TOPSIS modela tj. konačne poslovne ocjene. Razni softverski alati koji su razvijeni uz ove metode upućuju na korisničko jednostavniju i vizualno moćniju upotrebu kao i na mogućnost dodatnih analiza.

SAŽETAK

Nakon analize literature o performansama banaka, definirana su dva glavna stupca za financijsku i nefinancijsku ocjenu uspješnosti banaka. Prvi stupac pokrivaio je financijske pokazatelje dok je drugi stupac nefinancijske pokazatelje, korištena je podrška, značaj, menadžment i zrelost banke. Sveukupno gledano, uspješnost banaka ispitana je pomoću 14 kriterija. Korištenjem višekriterijskih modela obuhvaćeni su različiti kriteriji i respektirani njihovi različiti značaji.

Ključne riječi: višekriterijsko odlučivanje, evaluacija, performanse , komercijalne banke

SUMMARY

After analyzing bank literature on the performance of banks, two main columns for financial and non-financial rating of banks' performance were defined. The first column covered the financial indicators while the third column of the non-financial indicators was used, the support, significance, management and maturity of the bank. Overall, banks' performance was tested by 14 criteria. Using multi-criteria models, different criteria are covered and their different values are respected.

Keywords: multi-criteria decision-making, evaluation, performance, commercial banks

LITERATURA

1. Abdelgawad, M., Fayek, R. (2010): „Risk management in the construction, industry using combined fuzzy FMEA and fuzzy AHP“, *Journal of Construction Engineering and Management* Vol.136, No.9, 1028-1036.
2. Albadvi, A., Chaharsooghi, S., Esfahanipour, A. (2007): „Decision making in stock trading: An application of PROMETHEE“, *European Journal Of Operational Research*, Vol.177, No.2, 673-683.
3. Ayadi, O., Adebayo, O., Arinola, E., Omolehinwa, E. (1998): „Bank performance measurement in a developing economy: An application of data envelopment analysis“, *Managerial Finance*. Vol.24, 5-16.
4. Babić, Z., Belak, V. and Tomić-Plazibat, N. (1999): „Ranking of croatian banks according to business efficiency“, *Proceedings of the Fifth International Symposium on Operational Research*, Preddvor, Slovenia, 105-111.
5. Babić Z. (2011): *Modeli i metode poslovnog odlučivanja*, Ekonomski fakultet Split, Split.
6. Barros, C.P., Wanke, P., Emrouznejad, A. (2016): „Assessing productive efficiency of banks using integrated Fuzzy-DEA and bootstrapping: A case of Mozambican banks“, *European Journal of Operational Research*, Vol.249, No.1, 378-389.
7. Belak, V., Kolaković, M. (1998): „Organizacijska učinkovitost i reinženjering hrvatskih banaka“, *Slobodno poduzetništvo*, Vol.3, 3-17.
8. Belak, V. (1995): *Menadžersko računovodstvo, Računovodstvo, revizija i financije*, Zagreb.
9. Belak, V., Filipović, I. (1999): „Avoiding Bank Risk in Doing Business with Overindebted Clients“, *Proceedings of the Third International Conference on Enterprise in Transition*, Split-Šibenik, 561-566.
10. Brockett, P.L., Charnes, A., Cooper, W.W., Hwang, Z.M. and Sun, D.B. (1997): „Data transformations in DEA cone ratio envelopment approaches for monitoring bank performances“, *European Journal of Operational Research*, Vol.98, 250-268.
11. Brans, J.P., Mareschal, B., Vincke, Ph. (1986): „How to select and how to rank projects: The PROMETHEE method „, *European Journal of Operational Research*, Vol.24, 228-238.
12. Chapman, R.C., Cohen, A.B., David H.G. (2007): Chapman, C. S., Hopwood, A.G., Shields, M.D. (2007): „*Handbook of Management Accounting Research*“, Vol. 1., Elsevier.
13. Charnes, A., Cooper, W.W., Rhodes, E. (1978): „Measuring the efficiency of decision making units“, *European Journal of Operational Research*, Vol.2, No.6, 429-444.
14. Collier, H. W.; McGowan, C. B. (2010): Evaluating the impact of a rapidly changing economic environment on bank financial performance using the Du Pont system of financial analysis, *Asia Pacific Journal of Finance and Banking Research*, Vol.4, No.4, 25-35.
15. Cooper, W. W., Seiford, L. M., Tone K. (2000): „Data envelopment analysis: a comprehensive text with models, applications, references, and DEA-Solver software“, Kluwer Academic Publishers, Norwell

16. Cuong, X.D, Hoang, T.H., Long, T. (2017): „Multi-Criteria Decision-Making Model Evaluating the Performance of Vietnamese Commercial Banks“, *International Journal of Financial Research*, Vol. 9, No. 1, 132-141.
17. Čehulić, D., Hunjak, T., Begičević, N. (2011): „Comparison of a Bank's Financial Ratios Using the Analytic Hierarchy Process“, *Proceedings of the 22nd Central European Conference on Information and Intelligent Systems*, 187-193.
18. Dash, M., Charles, C. (2012): „An Analysis of the Technical Efficiency of Banks in India“, *IUP Journal of Bank Management*, Vol.11, No.4, 100-109.
19. Dash, M., Vegesna, S. (2014): „Efficiency of Public and Private Sector Banks in India“, *Journal of Applied Management and Investments*, Vol.3, No.3, 183-187.
20. Doumpos, M., Kosmidou, K., Baourakis, G., Zopounidis. C. (2002): „Credit risk assessment using amulticriteria hierarchical discrimination approach: A comparative analysis“, *European Journal of Operational Research*, Vol.138, 392-412.
21. Doumpos, M., Zopounidis, C. (2011): „A Multicriteria Approach to Bank Rating“, *Evaluation and Decision Models with Multiple Criteria: Case Studies*, eds. Bisdorf, R., Dias, L.C., Meyer, P., Mousseau, V., Pirot, M., *International Handbooks on Information Systems*, Springer.
22. Ginevičius, R. i Podvieszko, A. (2013): „The evaluation of financial stability and soundness of lithuanian banks“. *Economic research- Ekonomska istraživanja*, Vol.26, No.2, 191-208.
23. Gnanasekaran, M., Jebaraj, S., Ramu, M. (2008): „Assessment of selection criteria in sesame by using correlation coefficients, path and factor analyses“, *Plant Archives*, Vol.8, No.1, 167-169.
24. Hanley, C.A., Suter, M.P. (1997): „Banking's top performance“, *ABA Banking Journal*, Vol.89, No.7 , 36-40.
25. Harker, P., Vargas, L. (1987): „The Theory of Ratio scale Estimation: Saaty's Analytic Hierarchy Process“, *Management Science*, Vol.33, No.11.
26. Hunjak, T., Jakovčević, D. (2003): „Višekriterijski modeli za rangiranje i uspoređivanje banaka“, *Zbornik Ekonomskog fakulteta u Zagrebu*, godina 1, broj 1.
27. Investopedia. (2018): CAMELS Rating System. [online] Dostupno na: <https://www.investopedia.com › Personal Finance › Banking> [Pristupljeno 4 Tra. 2019].
28. Jabalameli, F., Rasoulinezhad, E. (2011): „The ranking of chosen branches of Saderat bank in Tehran city through the ahp and the dea“, *American Journal of Business and Management* Vol. 1, No. 1, 23-29.
29. Lindblom, T., Von Koch, C. (2002): „Cross-Border Bank Mergers and Acquisitions in the EU“, *The Service Industries Journal*, Vol. 22, No. 4, 41-72.
30. Lu, M.T., Tzeng, G.H., Tang, L.L. (2013): „Environmental strategic orientations for improving green innovation performance in fuzzy environment - using new fuzzy hybrid MCDM model“, *International Journal of Fuzzy Systems*, Vol.15, No.3, 297-316

31. Mareschal, B., Brans, J. (1991): „Bank adviser: An industrial evaluation system“, *European Journal of Operational Research*, Vol.54, 318-324.
32. Minh, N.K., Long, G.T., Hung, N.V. (2013): „Efficiency and Super-Efficiency of Commercial Banks in Vietnam: Performances and Determinants“, *Asia-Pacific Journal of Operational Research*, Vol.30, No.1, 1-19.
33. Parkan, C., Liu, M.L. (1999): „Measurement of the performance of an investment bank using the operational competitiveness rating procedure“, *Omega*, Vol.27, No.2, 201-217.
34. Saaty, T.L. (1980): *The Analytic Hierarchy Process*, McGraw-Hill, New York.
35. Saaty, T.L. (1990): „How to make a decision: The Analytic Hierarchy Process“, *European Journal of Operational Research*, Vol.48, No.1, 9-26.
36. Saaty, T.L., Vargas, L. (1994): „Decision making in economic, Political, Social and Tehnological Enviroments with the Analytic Hierarchy Process“, University of Pittsburgh, USA.
37. Srinivasan, V., Kim, Y.H. (1987): „Credit granting: A comparative analysis of classification procedures“, *The Journal of Finance*, XLII/3, 665-683.
38. Srinivasan, V., Ruparel, B. (1990): „CGX: An expert support system for credit granting“, *European Journal of Operational Research*, Vol.45, 293-308.
39. Stankevičienė, J., Mencaitė, E. (2012): „The Evaluation of bank performance using a multicriteria decision making model : A case study on Lithuanian commercial banks“, *Technological & Economic Development of Economy*, Vol.18, No.1, 189-205.
40. Šporčić, M., Martinic, I., Šegotić, K. (2009): „Application of Data Envelopment Analysis in Ecological Research of Maintenance of Forestry Mechanisation“, *Strojnicki Vestnik/Journal of Mechanical Engineering*, 55, No.10, 599-608.
41. Vujčić, B., Jemrić, I. (2002): „Efficiency of Banks in Croatia: A DEA Approach“, *Working Papers 7*, Croatian National Bank.
42. Wirnkar, A., Tanko, M. (2008): „CAMELS and banks performance evaluation: The way forward“, Retrieved May, 1-21.
43. Wu, C.R., Lin, C.T., Tsai, P.H. (2010): „Evaluating business performance of wealth management banks“, *European Journal of Operational Research*, Vol.207, No.2, 971-979.
44. Yeh, Q.J. (1996): "The Application of Data Envelopment Analysis in Conjunction with Financial Ratios for Bank Performance Evaluation", *Journal of the Operational Research Society*, Vol.47, No.8, 980-988.
45. Yoon, K.P., Hwang, C.L. (1995): *Multiple Attribute Decision Making*, Sage, Beverly Hills.

INTERNET IZVORI

[www. superdecisions.com](http://www.superdecisions.com)

www.promethee-gaia.net/software.htm

<https://www.hnb.hr/.../hbilten-o-bankama-30>

<https://www.hnb.hr/.../hbilten-o-bankama-29>

<https://www.hnb.hr/.../hbilten-o-bankama-29>

<https://www.investopedia.com>

POPIS SLIKA I TABLICA

Slika 3.1. Osnovni AHP model s ciljevima, kriterijima i alternativama

Slika 3.2. Obični kriterij

Slika 3.3. Kvazi kriterij

Slika 3.4. Kriterij s linearnom preferencijom

Slika 3.5. Nivo kriterij

Slika 3.6. Kriterij s linearnom preferencijom i područjem indifferencije

Slika 3.7. Gaussov kriterij

Slika 4.1. Potpuna hijerarhija unesena u program Super Decision

Slika 5.1. Kompletan poredak - PROMETHEE II (Visual Promethee)

Slika 5.2. Pozitivan, negativan i neto tok za svaku alternativu

Slika 5.3. Tablica odluke kod PROMETHEE metode u programu Visual Promethee

Slika 5.4. Kvadrati i norma

Slika 5.5. Vektorska transformacija

Slika 5.6. Udaljenost alternativa od idealne alternative

Slika 5.7. Kvadrati, suma i S_i^+

Slika 5.8. Udaljenost alternativa od antiidealne alternative

Slika 5.9. Kvadrati, suma i S_i –

Tablica 1.1. Vlasnička struktura banaka i udio njihove imovine u imovini svih banaka, na kraju razdoblja

Tablica 1.2. Kreditne institucije i sjedišta

Tablica 3.1. Saatyeva skala važnosti i njen opis

Tablica 3.2. Vrijednosti slučajnog indeksa

Tablica 3.3. Financijski kriteriji i potkriteriji

Tablica 3.4. Kriteriji i intenziteti za kvalitativno rangiranje

Tablica 3.5. Vrijednosti financijskih omjera

Tablica 3.6. Vrijednosti kvalitativnih pokazatelja

Tablica 4.1. Usporedba u parovima na drugoj razini hijerarhije

Tablica 4.2. Usporedba u parovima kod kvantitativnih podkriterija

Tablica 4.3. Usporedba u parovima kod kvalitativnih podkriterija

Tablica 4.4. Usporedba u parovima kod podkriterija Adekvatnost kapitala

Tablica 4.5. Usporedba u parovima kod podkriterija Efikasnost

Tablica 4.6. Usporedba u parovima kod podkriterija Likvidnost

Tablica 4.7. Usporedba u parovima kod podkriterija Profitabilnost

Tablica 4.8. Globalne težine kriterija, podkriterija i sekundarnih podkriterija

Tablica 5.1. Tablica odluke kod PROMETHEE metode

Tablica 5.2. PROMETHEE II-Kompletni poredak

Tablica 5.3. Tablica odluke kod TOPSIS metode

Tablica 5.4. Relativna bliskost i konačan poredak alternativa

Tablica 5.5. Komparacija poretka banaka kod PROMETHEE i TOPSIS metode